



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**FUTBOLCULARDA GÖRÜLEN HAMSTRİNG  
YARALANMALARININ TERMAL  
GÖRÜNTÜLEME VE YAPAY ZEKA İLE  
TESPİTİ**

**Mehmet Celalettin ERGENE**

**DOKTORA TEZİ**

**Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Ocak-2025**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Mehmet Celalettin ERGENE tarafından hazırlanan “Futbolcularda Görülen Hamstring Yaralanmalarının Termal Görüntüleme ve Yapay Zeka ile Tespiti” adlı tez çalışması 08/01/2025 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. H. Erdiñ KOÇER  
(Selçuk Üniversitesi)

.....

#### Danışman

Prof. Dr. Murat CEYLAN  
(Konya Teknik Üniversitesi)

.....

#### Üye

Doç. Dr. Hasan KOYUNCU  
(Konya Teknik Üniversitesi)

.....

#### Üye

Dr. Öğr. Üyesi Saim ERVURAL  
(KTO Karatay Üniversitesi)

.....

#### Üye

Dr. Öğr. Üyesi Ahmet SOLAK  
(Konya Teknik Üniversitesi)

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN  
Enstitü Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

İmza

Mehmet Celalettin ERGENE

Tarih: 08.01.2025

## ÖZET

### DOKTORA TEZİ

## FUTBOLCULARDA GÖRÜLEN HAMSTRİNG YARALANMALARININ TERMAL GÖRÜNTÜLEME VE YAPAY ZEKA İLE TESPİTİ

**Mehmet Celalettin ERGENE**

**Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. Murat CEYLAN  
2. Danışman: Dr. Öğr. Üyesi Ahmet BAYRAK**

**2025, 140 Sayfa**

**Jüri**

**Prof. Dr. Murat CEYLAN  
Prof. Dr. Hasan Erdiç KOÇER  
Doç. Dr. Hasan KOYUNCU  
Dr. Öğr. Üyesi Saim ERVURAL  
Dr. Öğr. Üyesi Ahmet SOLAK**

Futbol takımlarının başarısını etkileyen en önemli faktörler arasında oyuncu kalitesi, taktiksel düzenlemeler ve antrenman programları yer almaktadır. Ancak bu başarıyı olumsuz etkileyen başlıca faktörlerin başında futbolcu yaralanmaları gelmektedir. Aktif yaralanma yaşayan bir oyuncunun takıma katkı sağlayabilmesi mümkün olmamaktadır. Bundan dolayı yaralanmalar hem futbol takımlarının başarısını düşürmekte ve hem de tedavi masraflarından dolayı takımlara maliyetli olmaktadır. Bu olumsuzluklardan dolayı futbol takımları kas yaralanmalarının incelenmesi, erken evre tespiti, rehabilitasyon sürecinin takibi ve sahaya dönüşün karar verilmesinde ultrasonografi (USG), manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT), kan testleri ve izokinetik cihazlar gibi çeşitli tıbbi görüntüleme metotları kullanmaktadır. Günümüzde termografi alanındaki gelişmelerle birlikte termografik görüntüleme futbol takımlarına yaralanmaların incelenmesinde kullanımı kolay, maliyetsiz, kolay taşınabilir ve non-invaziv bir metot sunmaktadır. Yaralanmanın olduğu kas bölgesinde oluşan sıcaklık artışı ve kas bölgelerindeki sıcaklık asimetrisinden faydalanarak yaralanmaları incelemek mümkün olmaktadır. Bundan dolayı son dönemlerde sporcu yaralanmalarında termografinin kullanımı üzerine yapılan çalışmalar artış göstermektedir.

Bu tez çalışmasında, futbolcu yaralanmalarının termal görüntüleme ile incelenmesi ve bu görüntülerin yaralanma tespiti ile rehabilitasyon süreçlerinin planlanmasında kullanılabilirliği araştırılmıştır. Çalışmada, derin öğrenme yöntemleri kullanılarak alt ekstremitte termal görüntülerinden kas bölgelerinin segmentasyonu ve bu bölgelerdeki yaralanmaların sınıflandırılması yapılmıştır. Ayrıca, futbolcuların aktif yaralanmalarının tespiti ve rehabilitasyon süreçlerinin planlanmasına yönelik karar destek sistemleri geliştirilmiştir. Araştırma için Türkiye Süper Lig takımı futbolcularından 2 sezon boyunca termografi ile alt ekstremitte termal görüntüleri elde edilmiştir. Derin öğrenme metotlarında başarılı sonuçlar elde edebilmek için büyük miktarda veri gerekliliği olduğu bilirse de bir sezonda yaralanma yaşayan futbolcu sayısının sınırlı olması yetersiz ve dengesiz veri seti problemini ortaya çıkarmaktadır. Bu problemin üstesinden gelmek için geleneksel derin öğrenme metotlarına ek olarak, az örnekli öğrenme metotları ve yeni derin öğrenme metotları kullanılmıştır. Bu tez çalışmasında, aktif yaralanması bulunan futbolcuların termal görüntüleri incelenerek yaralanmaların tespiti yapılmış ve rehabilitasyon süreçleri planlanmıştır. Daha sonra bu yaralanmaların daha detaylı analiz edilebilmesi için derin öğrenme algoritmaları ile kas bölgelerinin segmentasyonu yapılmış ve segmente edilen bölgeler üzerinden yaralanmaların sınıflandırılması gerçekleştirilmiştir. Yetersiz ve dengesiz veri seti problemine

yönelik olarak, az örnekli öğrenme ve modern derin öğrenme metotları ile sınıflandırma süreçlerinin doğruluğu artırılmıştır.

Tez kapsamında yürütülen uygulamalar üç başlık altında gerçekleştirilmiştir. İlk olarak termal görüntülerden futbolcuların yaralanmaları tespit edilmiş ve yaralanmaların egzersiz etkisi altında verdiği termal tepki incelenmiştir. Aynı zamanda futbolcuların rehabilitasyon süreçlerinin planlanması ve sahaya dönüş kararının verilmesinde termografi desteği sağlanmıştır. Daha sonra futbolcularda anatomik atlasla göre belirlenen kas bölgeleri derin öğrenme metotlarından U-Net, Piramit Sahne Ayırıştırma Ağı, LinkNet ve Özellik Piramit Ağı kullanılarak segmente edilmiştir. Bu segmentasyon işlemi sonucunda; en başarılı metodun %99 başarı oranı ile U-Net olduğu görülmüştür. Daha sonra segmente edilen kas bölgelerindeki yaralanmaların tespit edilmesi için Densenet, Görsel Geometri Grubu, Artık Ağlar, EfficientNet gibi derin öğrenme metotları kullanılmıştır. Yaralanmaların tespiti için hem segmentasyon hem de sınıflandırma içeren bir uçtan uca bir algoritma yapısı tasarlanmıştır. Sınıflandırma sonucunda en başarılı sonuçları EfficientNetB0 %83.9 ve EfficientNetB1 + Özellik Piramit Ağı %81.0 doğruluk oranı ile vermiştir. Yetersiz ve dengesiz veri seti problemine çözüm bulmak ve elde edilen sonuçların başarı oranını daha da arttırmak için Siyam Ağları, Prototip Ağları ve Kolmogorov-Arnold Ağı ile sınıflandırma işlemi gerçekleştirilmiştir. Sınıflandırma sonuçları incelendiğinde Siyam ve Prototip Ağları sırasıyla %94 ve %97.78 başarı oranı elde ederken, Kolmogorov-Arnold Ağı ile %93.1 başarı oranı elde edilmiştir. Bu durum az örnekli öğrenme metotları ve derin öğrenmede yeni bir metot olan Kolmogorov-Arnold Ağı'nın sporcu yaralanmalarının termografi ile tespit edilmesinde oldukça başarılı olduğunu göstermektedir. Bunun yanında bu çalışma, Kolmogorov-Arnold Ağı ile termal görüntülerden yaralanma tespiti üzerine yapılan literatürdeki ilk çalışmalardandır. Sonuç olarak bu tez kapsamında yürütülen çalışmalar termografi ve derin öğrenme yöntemlerinin spor hekimliğinde etkin bir şekilde kullanılarak yaralanmaların tespitinde ve yönetiminde önemli bir katkı sunduğunu göstermektedir.

**Anahtar Kelimeler:** Az örnekli öğrenme, Derin öğrenme, Kolmogorov-Arnold ağı, Sporcu yaralanmaları, Termografi, Yaralanma tespiti

## **ABSTRACT**

### **PhD THESIS**

## **DETECTION OF HAMSTRING INJURIES ON FOOTBALL PLAYERS WITH THERMAL IMAGING AND ARTIFICIAL INTELLIGENCE**

**Mehmet Celalettin ERGENE**

**Konya Technical University  
Institute of Graduate Studies  
Department of Electrical and Electronics Engineering**

**Advisor: Prof. Dr. Murat CEYLAN  
Co-Advisor: Asst. Prof. Ahmet BAYRAK**

**2025, 140 Pages**

### **Jury**

**Prof. Dr. Murat CEYLAN  
Prof. Dr. Hasan Erdiç KOÇER  
Assoc. Prof. Hasan KOYUNCU  
Asst. Prof. Saim ERVURAL  
Asst. Prof. Ahmet SOLAK**

Among the key factors influencing the success of football teams are player quality, tactical arrangements, and training programs. However, one of the primary factors negatively impacting this success is player injuries. An active injury prevents a player from contributing to the team, thereby reducing team performance and incurring additional costs for treatment. Consequently, football teams utilize various medical imaging methods, including ultrasonography, magnetic resonance imaging, computed tomography, blood tests, and isokinetic devices, to examine muscle injuries, enable early diagnosis, monitor rehabilitation processes, and determine return-to-play decisions. Recent advancements in thermography have introduced thermographic imaging as a cost-effective, portable, non-invasive, and user-friendly method for injury analysis in football teams. By utilizing temperature asymmetry and increased heat in the injured muscle region, thermography enables detailed examination of injuries. This has led to a rise in studies focusing on the use of thermography in sports injuries in recent years.

This thesis investigates the use of thermographic imaging in analysing football player injuries and its applicability in injury detection and rehabilitation planning. The study utilizes deep learning methods to segment muscle regions from lower extremity thermographic images and classify injuries in these regions. Additionally, decision support systems for the detection of active injuries and planning of rehabilitation processes in football players were developed. For the research, lower extremity thermographic images were collected from football players in a Turkish Super League team over two seasons. Although large datasets are generally required to achieve successful results in deep learning methods, the limited number of injured players per season presents challenges in achieving balanced datasets. To overcome this issue, in addition to traditional deep learning methods, few-shot learning techniques and novel deep learning methods were employed.

In this thesis, the thermographic images of football players with active injuries were analyzed, and their injuries were detected, followed by planning their rehabilitation processes. Subsequently, deep learning algorithms were utilized to segment muscle regions for more detailed analysis of these injuries, and the segmented regions were classified to identify injuries. To address the issue of insufficient and imbalanced datasets, few-shot learning and modern deep learning methods were employed to enhance classification accuracy.

The implementations conducted within the scope of the thesis were carried out under three main stages. First, injuries in football players were detected from thermographic images, and the thermal

response of injuries under exercise was analyzed. Additionally, thermography was used to assist in planning rehabilitation processes and determining return-to-play decisions. Subsequently, muscle regions identified based on the anatomic atlas were segmented using deep learning methods such as U-Net, Pyramid Scene Parsing Network, LinkNet, and Feature Pyramid Network. The segmentation results demonstrated that U-Net achieved the highest performance with a success rate of 99%. Following the segmentation, injuries in the segmented muscle regions were detected using deep learning methods such as DenseNet, Visual Geometry Group, ResNet, and EfficientNet. An end-to-end algorithm structure encompassing both segmentation and classification was designed for injury detection. The classification results indicated that the highest accuracy rates were achieved with EfficientNetB0 (83.9%) and EfficientNetB1 + Feature Pyramid Network (81.0%).

To further enhance accuracy and address the issue of imbalanced datasets, classification was also performed using Siamese Networks, Prototypical Networks, and Kolmogorov-Arnold Network. The classification results showed that the Siamese and Prototypical Networks achieved success rates of 94% and 97.78%, respectively, while the Kolmogorov-Arnold Network achieved a success rate of 93.1%. This demonstrates the effectiveness of few-shot learning methods and the Kolmogorov-Arnold Network, a novel deep learning method, in detecting sports injuries using thermography. Furthermore, this study is among the first in the literature to use Kolmogorov-Arnold Networks for injury detection from thermographic images.

In conclusion, the studies conducted within the scope of this thesis demonstrate the significant contribution of thermography and deep learning methods to sports medicine by enabling effective injury detection and management.

**Keywords:** Deep learning, Few-shot learning, Injury detection, Kolmogorov-Arnold network, Sports injuries, Thermography

## ÖNSÖZ

Doktora tez çalışma sürecimde bana rehberlik eden ve akademik hayatım boyunca değerli katkılarda bulunan danışmanım Konya Teknik Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Elektrik-Elektronik Mühendisliği Öğretim Üyesi Sayın Prof. Dr. Murat CEYLAN'a teşekkürü borç bilirim.

Doktora tez çalışmam süresince futbolcu termal görüntülerinin alınmasında, değerlendirilmesinde ve akademik çalışmalar süresince yardımlarını esirgemeyen ikinci danışmanım Selçuk Üniversitesi Spor Bilimleri Fakültesi Öğretim Üyesi Sayın Dr. Öğr. Üyesi Ahmet BAYRAK'a sonsuz şükranlarımı sunarım

Son olarak hayatımın her adımında desteklerini hissettiğim değerli aileme ve sevgisiyle beni destekleyip cesaretlendiren, doktora çalışmamın ve hayatımın her aşamasında yanımda olan ve gelecekte de çok başarılı bir hekim olacağını bildiğim sevgili eşim Dr. Beyza GÜZELKARA ERGENE'ye en içten teşekkürlerimi sunarım.

Mehmet Celalettin Ergene  
KONYA-2025

## İÇİNDEKİLER

|                                                                              |             |
|------------------------------------------------------------------------------|-------------|
| <b>ÖZET .....</b>                                                            | <b>iv</b>   |
| <b>ABSTRACT.....</b>                                                         | <b>vi</b>   |
| <b>ÖNSÖZ .....</b>                                                           | <b>viii</b> |
| <b>İÇİNDEKİLER .....</b>                                                     | <b>ix</b>   |
| <b>SİMGELER VE KISALTMALAR .....</b>                                         | <b>xii</b>  |
| <b>1. GİRİŞ .....</b>                                                        | <b>1</b>    |
| 1.1. Kapsam ve Amaç .....                                                    | 1           |
| 1.2. Sporcu Yaralanmaları .....                                              | 1           |
| 1.3. Termal Görüntüleme .....                                                | 3           |
| 1.4. Araştırma Soruları ve Hipotezler .....                                  | 6           |
| 1.5. Tezin Yapısı .....                                                      | 7           |
| <b>2. KAYNAK ARAŞTIRMASI .....</b>                                           | <b>9</b>    |
| 2.1. Sporcu Yaralanmalarında Kullanılan Metotlar .....                       | 9           |
| 2.1.1. Ultrasonografi Kullanımı .....                                        | 10          |
| 2.1.2. Bilgisayarlı Tomografi Kullanımı .....                                | 12          |
| 2.1.3. Manyetik Rezonans Görüntüleme (MRG) Kullanımı .....                   | 13          |
| 2.1.4. Kan Testleri ve İzokinetik Cihaz Kullanımı .....                      | 15          |
| 2.1.5. Termal Görüntüleme Kullanımı .....                                    | 16          |
| 2.2. Sporcu Yaralanmalarının Yapay Zeka ile Tespiti .....                    | 19          |
| <b>3. MATERYAL VE YÖNTEM .....</b>                                           | <b>22</b>   |
| 3.1. Veri Seti .....                                                         | 22          |
| 3.2. Yöntemler .....                                                         | 25          |
| 3.2.1. Termal Görüntülerden Kas Segmentasyonu .....                          | 25          |
| 3.2.1.1 U-Net .....                                                          | 26          |
| 3.2.1.2 Piramit Sahne Ayrıştırma Ağı (PSPNet) .....                          | 28          |
| 3.2.1.3 LinkNet .....                                                        | 30          |
| 3.2.1.4 Özellik Piramit Ağı .....                                            | 32          |
| 3.2.2. Yaralanma Sınıflandırması için Kullanılan Yapay Zeka Yöntemleri ..... | 34          |
| 3.2.2.1. Densenet .....                                                      | 35          |
| 3.2.2.2. Görsel Geometri Grubu (GGG) .....                                   | 37          |
| 3.2.2.3. Artık Ağlar (ResNet) .....                                          | 39          |
| 3.2.2.4. EfficientNet .....                                                  | 41          |
| 3.2.2.5. Siyam Ağları .....                                                  | 43          |
| 3.2.2.6. Prototip Ağları .....                                               | 45          |
| 3.2.2.7. Kolmogorov-Arnold Ağı .....                                         | 46          |
| 3.3. Performans Değerlendirme Ölçütleri .....                                | 49          |

|                                                                                                                                                                              |           |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|
| <b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>                                                                                                                               | <b>52</b> |
| 4.1. Termografinin Sporcu Yaralanmalarında Kullanımı .....                                                                                                                   | 52        |
| 4.1.1. Futbolda Menisküs Yaralanmalarının Belirlenmesinde Termografinin Kullanımı .....                                                                                      | 52        |
| 4.1.1.1. Vaka Sunumu ve Sonuçlar.....                                                                                                                                        | 53        |
| 4.1.1.2. Tartışma .....                                                                                                                                                      | 55        |
| 4.1.2. Profesyonel Bir Futbolda Rektus Femoris Proksimal Yırtığı Sonrası Kızılötesi Termografi ile Spora Dönüş Sürecinin Değerlendirilmesi.....                              | 56        |
| 4.1.2.1 Vaka Sunumu.....                                                                                                                                                     | 57        |
| 4.1.2.2 Araştırma Sonuçları ve Tartışma .....                                                                                                                                | 58        |
| 4.1.3. Egzersizin Etkisi Altında Kas Yaralanmalarının Tespitinde Termografi Yöntemi: Sartorius Kası Örneği .....                                                             | 63        |
| 4.1.3.1. Vaka Sunumu.....                                                                                                                                                    | 64        |
| 4.1.3.2. Araştırma Sonuçları ve Tartışma .....                                                                                                                               | 65        |
| 4.1.4. Operatif Yolla Tedavi Edilen Proksimal Rektus Femoris Tendon Ruptürü Yaralanması Öyküsü Olan Sporcunun Antrenman Etkisi Altında Termografi ile Değerlendirilmesi..... | 69        |
| 4.1.4.1. Vaka Sunumu.....                                                                                                                                                    | 69        |
| 4.1.4.2. Araştırma Sonuçları ve Tartışma .....                                                                                                                               | 71        |
| 4.1.5. Rektus Femoris Proksimal Yırtık Geçmiş Olan Sporcuların Antrenman Yüküne Verdikleri Tepkinin Termografi ile İzlenmesi .....                                           | 71        |
| 4.1.5.1. Vaka 1 .....                                                                                                                                                        | 72        |
| 4.1.5.2. Vaka 2 .....                                                                                                                                                        | 72        |
| 4.1.5.3. Araştırma Sonuçları ve Tartışma .....                                                                                                                               | 72        |
| 4.1.6. Profesyonel Futbolcuların Egzersiz Planlaması İçin Kızılötesi Termografi Kullanımı .....                                                                              | 76        |
| 4.1.6.1. Araştırma Sonuçları ve Tartışma .....                                                                                                                               | 76        |
| 4.2. Termal Görüntülerden Kas Segmentasyonu Çalışmaları.....                                                                                                                 | 80        |
| 4.2.1. Termal Görüntülemeye Alt Ekstremitte Kas Segmentasyonu için Derin Öğrenme Modellerinin Değerlendirilmesi.....                                                         | 81        |
| 4.2.1.2 Araştırma Bulguları ve Tartışma .....                                                                                                                                | 81        |
| 4.3. Termal Görüntülerden Yaralanma Sınıflandırması .....                                                                                                                    | 88        |
| 4.3.1. Profesyonel Futbolcularda Yaralanmaların Termografi ve Görüntü İşleme ile İzlenmesi.....                                                                              | 88        |
| 4.3.1.1 Kullanılan Görüntü İşleme Algoritması .....                                                                                                                          | 88        |
| 4.3.1.2 Araştırma Sonuçları ve Tartışma .....                                                                                                                                | 91        |
| 4.3.2 Profesyonel Futbolcularda Termal Görüntülerden Hamstring Yaralanmalarının Tespiti İçin Derin Öğrenme Modellerinin Kullanımı .....                                      | 95        |
| 4.3.2.1 Hamstring Segmentasyonu İçin Kullanılan Model.....                                                                                                                   | 96        |
| 4.3.2.2 Hamstring Yaralanması Sınıflandırması İçin Kullanılan Modeller.....                                                                                                  | 97        |
| 4.3.2.3 Araştırma Sonuçları .....                                                                                                                                            | 98        |
| 4.3.2.4 Tartışma .....                                                                                                                                                       | 100       |
| 4.3.3 Hamstring Yaralanmasının Belirlenmesinde Prototip ve Siyam Ağlarının Kullanımı .....                                                                                   | 102       |
| 4.3.3.1 Sınıflandırma İçin Kullanılan Modeller.....                                                                                                                          | 103       |
| 4.3.3.2 Araştırma Sonuçları ve Tartışma .....                                                                                                                                | 104       |
| 4.3.4 Profesyonel Futbolcularda Alt Ekstremitte Yaralanmalarının Kızılötesi Termografi ile Sınıflandırılmasında Kolmogorov-Arnold Ağlarının Kullanımı ..                     | 107       |
| 4.3.4.1 Sınıflandırma İçin Kullanılan Model.....                                                                                                                             | 107       |

|                                               |            |
|-----------------------------------------------|------------|
| 4.3.4.2 Araştırma Sonuçları ve Tartışma ..... | 108        |
| <b>5. SONUÇLAR VE ÖNERİLER .....</b>          | <b>111</b> |
| 5.1. Sonuçlar .....                           | 111        |
| 5.1.1. Ana Bulgular .....                     | 111        |
| 5.1.2. Tezin Katkıları .....                  | 113        |
| 5.2 Öneriler .....                            | 114        |
| 5.2.1. Gelecek Araştırma Önerileri .....      | 114        |
| 5.2.2. Çalışmanın Uygulama Alanları .....     | 115        |
| <b>KAYNAKLAR .....</b>                        | <b>118</b> |
| <b>EKLER .....</b>                            | <b>128</b> |



## SİMGELER VE KISALTMALAR

### Simgeler

|                           |                                             |
|---------------------------|---------------------------------------------|
| $^{\circ}\text{C}$        | : Santigrat derece                          |
| cm                        | : Santimetre                                |
| $d(A, B)$                 | : Öklid mesafesi                            |
| $f(x_1, x_2, \dots, x_n)$ | : Çok değişkenli fonksiyon                  |
| Hz                        | : Hertz                                     |
| km                        | : Kilometre                                 |
| m                         | : Metre                                     |
| max                       | : Maksimum                                  |
| mm                        | : Milimetre                                 |
| MHz                       | : Megahertz                                 |
| nm                        | : Nanometre                                 |
| $\Lambda$                 | : Dalga boyu                                |
| L                         | : Kayıp                                     |
| log                       | : Logaritma                                 |
| $\phi_q$                  | : Tek değişkenli aktivasyon                 |
| $\Psi_{pq}$               | : Kolmogorov-Arnold Ağı ara katman bileşeni |
| s                         | : Saat                                      |

### Kısaltmalar

|     |                                 |
|-----|---------------------------------|
| BT  | : Bilgisayarlı tomografi        |
| ESA | : Evrişimsel sinir ağları       |
| DN  | : Doğru negatif                 |
| DP  | : Doğru pozitif                 |
| GGG | : Görsel geometri grubu         |
| GPU | : Grafik işlemci birimi         |
| KAN | : Kolmogorov-Arnold Ağı         |
| KK  | : Kreatin kinaz                 |
| MR  | : Manyetik rezonans             |
| MRG | : Manyetik rezonans görüntüleme |
| ÖPA | : Özellik piramit ağı           |
| RF  | : Rectus femoris                |
| RGB | : 3 boyutlu renk uzayı          |
| USG | : Ultrasonografi                |
| YN  | : Yanlış negatif                |
| YP  | : Yanlış pozitif                |
| YSA | : Yapay sinir ağı               |

## 1. GİRİŞ

### 1.1. Kapsam ve Amaç

Günümüzde futbol, yalnızca bir spor dalı değil, aynı zamanda teknolojik ve bilimsel yeniliklerin de uygulandığı bir platform haline gelmiştir. Futbolcuların performansının artırılması ve yaralanmalarının önlenmesi hem bireysel kariyerlerin korunması hem de takımların başarısının sürdürülebilirliği açısından kritik öneme sahiptir. Futbolcularda meydana gelen yaralanmalar, yalnızca oyuncuların kariyerini değil, kulüplerin başarısını ve uzun vadeli hedeflerini de doğrudan etkilerken, futbol kulüplerinin sağlık harcamaları için ayırdığı bütçeyi de arttırmaktadır. (Ludvigsen, 2022). Bu nedenle, kas yaralanmalarının erken tespiti, doğru teşhisi ve önlenmesi, futbol dünyasında daha fazla önem kazanmaktadır. Bu yaralanmaların tespit edilmesi, engellenmesi ve rehabilitasyon takibi için çeşitli medikal görüntüleme metotları kullanılmaktadır. Termografi bir diğer adıyla termal görüntülemedeki son gelişmeler futbolcuların kas yaralanmalarının tespit edilebilmesinde önemli ölçüde rol oynamaktadır (Bayrak ve diğ., 2024). Bu tez ise termografi ve yapay zekanın birlikte kullanımıyla futbolcularda meydana gelen hamstring yaralanmalarının tespit edilebilmesini amaçlamıştır.

### 1.2. Sporcu Yaralanmaları

Futbol takımlarının başarılarını etkileyen faktörler arasında oyuncu kalitesi, taktikler, antrenman ve beslenme programı gibi birçok değişken bulunmaktadır. Takımların başarısına negatif yönde etki eden faktörlerden biri ise futbolcuların yaralanmaları olarak görülmektedir. Bu bağlamda bir futbol takımında oyuncu kalitesi ve stratejik taktiklerin önemi ne kadar büyük olursa olsun, aktif yaralanma yaşayan bir oyuncunun takıma katkı sağlayabilmesi mümkün olmamaktadır. İstatistikler, İngiliz Premier Ligi'nde bir futbolcunun yaralanmalarının bir sezonda kulübe maliyetinin 8 milyon sterline kadar ulaşabileceğini ve oyunculara ödenen maaşların %22,44'e kadar olan kısmının bu süreçte verimsiz kullanıldığını göstermektedir (McKenna, 2024). Avrupa'nın önde gelen liglerinden biri olan İspanya Futbol Ligi'nde yapılan bir çalışmaya göre, futbolcularda meydana gelen yaralanmaların bir takıma aylık maliyeti 365.000 €'ya kadar çıkabilirken, toplamda yıllık 7,3 milyon € gibi ciddi bir ekonomik

yük oluşturduğu görülmüştür (Nieto Torrejón ve diğ., 2024). Avustralya Profesyonel Futbol Ligi'nde beş sezon boyunca yapılan bir çalışmada, yaralanmaların toplam maliyetinin yaklaşık 2,3 milyon Avustralya Doları olduğu belirlenmiştir. Bu tutarın, bir takımın iki oyuncusunun bir sezonluk maaşına denk geldiği ifade edilmektedir (Lu ve diğ., 2021). Ligin seviyesine göre yayın gelirleri ve futbolcu maaşları göz önüne alındığında Avustralya gibi görece küçük bir ligde bile yaralanma maliyetlerinin çok yüksek meblağlara ulaşabileceği açıkça görülmektedir (Carreras ve Garcia, 2018).

Futbolcu yaralanmaları, yarattıkları ekonomik sıkıntıların yanında takımların başarılarına da doğrudan etki etmektedir (Everett ve diğ., 2024). Doğal olarak, yaralanma nedeniyle oyuncuların maçlarda süre kaybı yaşaması, futbol takımlarının taktiksel planlamalarını doğrudan etkilemektedir. Başarıya etki eden bir diğer faktör ise antrenman miktarıdır. Futbolcularda antrenman süresini arttırmak takım başarısını arttırmaktadır. Ancak antrenman süresinin artmasının başarıyı başarıya etkisi olsa da futbolcularda aşırı yüklenme kaynaklı yaralanma riskini de beraberinde getirmekte ve futbolcu yaralanmalarının büyük bir kısmı antrenmanlarda gerçekleşmektedir (Jiang ve diğ., 2022). İngiltere Premier Ligi 2020-2021 yılını inceleyen bir çalışmaya göre bir önceki sezonda başarı elde eden takımlarda yaralanmaların artması ile lig sıralarında düşüş meydana gelmiştir. Ayrıca ligi ilk üç sırada bitiren takımların kilit oyuncularının en çok antrenman yapanlar olduğu ve yaralanmalarının az olduğu görülmüştür (Chang ve diğ., 2024). Yapılan bir diğer çalışmada ise COVID-19 sonrası yoğunlaşan maç takviminin futbolculardaki kas hasarı üzerine etkisi incelenmiştir. Çalışmada kreatin kinaz (KK) seviyeleri ve GPS verileri kullanılarak futbolcularda oluşan fiziksel yüklenme takip edilmiştir. Araştırmanın bulgularında ise artan maç yoğunluğunun kas hasarını arttırdığını ve fiziksel toparlanmayı zorlaştırdığı gözlemlenmiştir. Çalışma sonucunda antrenman programlarının bu tür yoğunluklara uygun planlanmasının önemi vurgulanmıştır (Garcia-Unanue ve diğ., 2024). Futbolcularda hamstring kasının incelendiği bir diğer çalışmada ise futbolcularının kas durumu ve yorgunluğunun düzenli olarak takip edilmesi gerektiği ve yaralanmaların önlenmesi için yorgunluk izleme ve mekanik dayanıklılık değerlendirmesinin kritik öneme sahip olduğu vurgulanmıştır. Aynı zamanda futbolcularda düzenli takip ve kişiselleştirilmiş yük yönetimi stratejilerinin yaralanmaları önlemek ve performansı artırmak için uygulanabilir olduğu sonucuna varılmıştır (Martínez Serrano, 2024). Futbolcularda yaralanma risk faktörleri ve önleyici stratejiler üzerine yoğunlaşan başka bir çalışmada ise oyuncuların antrenman yükü, toparlanma süreleri ve yaralanma risk faktörleri


arasındaki ilişki vurgulanmıştır. Ayrıca, düzenli yük planlaması, GPS ve modern izleme teknolojilerinin kullanımı ile risklerin azaltılabileceği belirtilmiştir (Pillitteri ve diğ., 2024). Genç futbolcularda antrenman yükündeki artışın başarıya olan etkisinin incelendiği bir çalışmada yüksek yoğunluklu antrenmanlar sayesinde futbolcularda dayanıklılık, güç, beceri ve takım koordinasyonunda artış incelenmiş olup antrenman yoğunluğunun, performansı arttırmanın yanı sıra oyun içindeki bireysel ve takım becerilerini geliştirmek için etkili bir yöntem olarak öne çıktığı görülmüştür (Fadhil ve diğ., 2024). Literatürde antrenman yükü ve maç yoğunluğu üzerine yapılan çalışmalar incelendiğinde futbolcularda yaşanan yaralanmaların antrenman planlaması ve yaralanma önleme mekanizmaları sayesinde yönetilmesi ve yaralanmaların azaltılmasının futbol kulüplerinin başarısı için önemli olduğu görülmektedir.

Yaralanmaların meydana getirdiği performans ve ekonomik zararlardan dolayı futbol takımları bu yaralanmaları önceden tespit etmek veya yaralanma daha erken evredeyken önüne geçmek için ultrasonografi (USG), manyetik rezonans görüntüleme (MRG), bilgisayarlı tomografi (BT), kan testleri ve izokinetik cihazlar gibi çeşitli metotlara başvurmaktadır. Son dönemlerde ise diğer metotlara kıyasla daha ucuz, kullanımı kolay ve invaziv olmayan bir metot olan termal görüntüleme güncel çalışmaların odağı olmaya başlamıştır.

### 1.3. Termal Görüntüleme

Termografi, nesnelerin yüzey sıcaklıklarını görünür hale getiren bir görüntüleme tekniğidir. Genellikle kızılötesi termografi olarak bilinen bu yöntem, elektromanyetik spektrumun kızılötesi bölgesinde radyasyon yayan cisimlerin tespit edilmesi ve ölçülmesi prensibine dayanmaktadır. İnsan gözünün algılayamayacağı bu kızılötesi ışıınlar, özel sensörler yardımıyla tespit edilerek termal görüntüler oluşturulur. Bu termal görüntüler, genellikle farklı sıcaklık aralıklarını temsil eden renk tonları ile ifade edilir ve cisimlerin sıcaklık dağılımını ayrıntılı bir şekilde görselleştirir (Wolfe ve Zissis, 1978; Schuster ve Kolobrodov, 2004). Her nesne, sıcaklığına bağlı olarak belirli bir dalga boyunda kızılötesi radyasyon yayar (Şekil 1.1). Stefan-Boltzmann Yasası, bir nesnenin yüzey sıcaklığının artmasıyla birlikte yaydığı toplam enerji miktarının da önemli ölçüde arttığını belirten temel bir fizik yasasıdır (Wolfe ve Zissis, 1978). Bu yasa, özellikle termal görüntüleme ve radyasyon ısınmasıyla ilgili alanlarda kullanılmaktadır. Termografi, bir nesnenin yüzeyindeki sıcaklık farklılıklarını kızılötesi

radyasyonla ölçer. Stefan-Boltzmann Yasası'nın bu ölçümlerde oynadığı rol şu şekilde özetlenebilir; Bir nesnenin sıcaklığı arttıkça, yaydığı kızılötesi radyasyon miktarı hızla artar. Bu da termal kameralar tarafından daha net ve parlak bölgelerin görünmesini sağlar. Örneğin, vücutta iltihaplanan bir bölge, çevresindeki dokulara göre daha sıcak olduğu için daha fazla kızılötesi radyasyon yayar ve termal görüntüde parlak bir şekilde görünür. Bu nedenle, sıcaklık değişimleri bir nesnenin kızılötesi ışınımında büyük farklılıklar yaratır (Gaussorgues ve Chomet, 2012). Termal kameralar, bu radyasyonu algılayarak ve analiz ederek her bir piksel için sıcaklık değerini hesaplar.



Şekil 1.1. Elektromanyetik dalga spektrumu içerisinde kızılötesi spektrum (750nm – 1mm)

Termografik görüntüleme geçmişten günümüze tarım, endüstri, sağlık, arkeolojik, ormancılık gibi birçok alanda sıklıkla kullanılmaktadır. Termografi, tarımda bitki stresinin tespiti (Takayama ve Nishina, 2007), endüstride enerji verimliliğinin artırılması (Lucchi, 2018), sağlıkta hastalık tanısı koyarken karar destek mekanizması olarak kullanılması (Lozano III ve Hassanipour, 2019), ormancılıkta ağaç sağlığının değerlendirilmesi (Smigaj ve diğ., 2024) ve arkeolojide tarihi binaların sağlığının izlenmesi (Nandhitha ve diğ., 2021) gibi geniş bir kullanım alanına sahiptir. Bu çalışmalara ek olarak kızılötesi görüntüleme Amerika Birleşik Devletleri Gıda ve İlaç Dairesi (FDA) tarafından sağlık alanında destek mekanizması olarak onaylanmıştır (Rakhunde ve diğ., 2022).

Günümüzde, futbolcularda kas yaralanmalarının analizi amacıyla kullanılan çeşitli tıbbi görüntüleme sistemleri bulunmaktadır. Bu yöntemler arasında, yumuşak doku değerlendirmesi için USG ve MRG, kemik dokularının incelenmesi için röntgen, hem yumuşak hem de kemik dokuların değerlendirilmesi için ise BT öne çıkmaktadır. Bu cihazların görüntüleme kaliteleri gün geçtikçe iyiye giderken en büyük dezavantajları ise cihazların çok pahalı olması, çekim süresinin uzun sürmesi ve bazı metotların sık kullanılması durumunda dokuda istenmeyen etkiler oluşma ihtimalidir. Bu nedenle, futbol takımları düşük maliyetli, hızlı ve non-invaziv özelliklere sahip alternatif görüntüleme yöntemleri araştırmaya yönelmiştir.

Termografi, non-invaziv bir yöntem olması nedeniyle vücuda herhangi bir girişim gerektirmeden uygulanmakta ve bu özelliğiyle hastaya zarar vermemektedir. Ayrıca, çekim sürecinin kolaylığı ve hızlı sonuç verebilmesi, yöntemi pratik ve etkili bir görüntüleme aracı haline getirmektedir. Bu sayede, takımdaki oyuncu sayısının fazlalığı göz önüne alındığında, her bir oyuncunun yaralanma durumunun tek tek incelenmesinin zorluğu karşısında pratik ve kolay bir değerlendirme imkânı sunmaktadır. İyonlaştırıcı radyasyon içermemesi nedeniyle termografi, röntgen ve BT gibi bazı görüntüleme yöntemlerine kıyasla tekrarlayan tarama gerektiren durumlarda önemli bir avantaj sağlamaktadır. Bu özelliği, özellikle radyasyona bağlı potansiyel hücresel hasar ve uzun vadede oluşabilecek sağlık risklerini önlemesi açısından kritik bir önem taşımaktadır. Sadece mevcut sorunları tespit etmek değil, aynı zamanda önleyici bakım ve izleme amacıyla da kullanılabilir. Sporcularda, kaslarda veya eklemlerde olası iltihaplanmalar ya da aşırı yüklenmeler erken safhada tespit edilip önlem alınabilmektedir. Son olarak, diğer metotlara kıyasla daha düşük maliyetli olması sebebiyle de tıbbi görüntülemede sıklıkla kullanılmaya başlanmıştır (Ng, 2003; da Silva ve diğ., 2024).

Sonuç olarak, kızılötesi görüntülemedeki gelişmeler ışığında termografinin aktif ve efektif bir görüntüleme metodu olduğu açıkça görülmektedir. Barındırdığı birçok avantajın yanı sıra, termografi yöntemi büyük miktarda görüntü verisinin tek tek incelenmesinin zaman alıcı olması gibi bir dezavantaja sahiptir. Ayrıca, analizlerin inceleyen uzmanın yorumuna dayalı olarak subjektif bir nitelik taşıması, yöntemin hata yapmaya açık olmasına neden olmaktadır. Bu dezavantajın önüne geçmek için makine öğrenmesi ve derin öğrenme gibi metotlar günümüzde kullanılmaya başlanmıştır. Kızılötesi görüntüleme ve yapay zekanın birlikte kullanımı ile analiz süresini ve başarısını optimize etmek mümkün olmaktadır. Gelecekte, bu tür yaklaşımların

geliştirilmesiyle termografinin farklı disiplinlerde daha yaygın bir şekilde kullanılması, sağlık alanında karar destek mekanizmalarının etkinliğinin artırılmasına, ziraat alanında bitki sağlığının korunarak ürün verimliliğinin artırılmasına olanak tanıyacaktır. Ayrıca, endüstriyel uygulamalarda sistemlerin verimliliğinin optimize edilmesine katkı sağlayarak, çeşitli alanlarda insan yaşamına önemli faydalar sunması beklenmektedir.

Bu tez kapsamında, futbolcu termal görüntülerinin analizi gerçekleştirilmiş; kas bölgelerinin detaylı incelenmesi ve potansiyel yaralanmaların tespiti amacıyla derin öğrenme algoritmalarının uygulanmasına yönelik çeşitli çalışmalar yürütülmüştür. Bu çalışmaların sonuçlarının futbol takımları tarafından benimsenmesi durumunda, termografinin futbolcuların yaralanmalarının erken teşhisinde daha etkili bir araç haline gelebileceği ve buna bağlı olarak takımların başarılarının artmasının yanı sıra sağlık harcamalarındaki maliyetlerin de azalabileceği öngörülmektedir.

#### **1.4. Araştırma Soruları ve Hipotezler**

Yapay zeka ve kızılötesi termografinin ortak kullanımı, görüntüleme teknolojilerinde önemli bir ilerleme sağlamaktadır. Bu birleşimden doğacak yeniliklerin insan hayatına ve endüstriye birçok fayda sağlayacağı öngörülmektedir. Bu çalışmada da bu iki teknolojinin bir arada kullanımı için yeni bir yaklaşım sunulmuştur. Bu çalışmanın amacı yapay zeka desteği ile futbolcu termal görüntülerinden kas segmentasyonu ve yaralanma tespiti yapmaktır. Bu bağlamda çalışmaya yönelik çeşitli sorular ve hipotezler aşağıdaki gibi olacaktır:

- 1) Termografinin sporcu yaralanmalarının tespiti ve analizi üzerindeki etkisi nedir?
- 2) Termografi, diğer tıbbi görüntüleme yöntemlerine kıyasla futbolcularda yaralanmaların tanısında nasıl bir avantaj sunar?
- 3) Termal görüntüleme, yaralanma sonrası iyileşme sürecinin takibinde etkili bir yöntem midir?
- 4) Termografi ve yapay zeka birleşimi, termal görüntülerde kas bölgelerinin segmentasyonunda ne kadar başarılıdır?
- 5) Termal görüntülerden kas bölgesi segmentasyonunda başarı kriterleri nelerdir? Hangi yöntemler en yüksek başarıyı elde etmiştir?
- 6) Termal görüntülerde yaralanma sınıflamasında başarı kriterleri nelerdir? Hangi yöntemler en yüksek başarıyı elde etmiştir?

- 7) Termografinin yapay zeka ile birlikte kullanımı, kas yorgunluğu ve aşırı kullanım kaynaklı yaralanmaların erken tespitinde ne kadar başarılıdır?
- 8) Sadece termal görüntülerden değil, aynı zamanda bu görüntülerden elde edilen sayısal sıcaklık verileri kullanılarak yaralanma tespiti yapmak mümkün müdür?

Bu çalışma boyunca araştırma sorularına yönelik hipotezler oluşturularak yanıtlar elde edilmiştir. Elde edilen yanıtlar doğrultusunda, futbolcularda yaralanmaların önlenmesine katkı sağlamak amacıyla yapay zeka destekli bir yaralanma tespiti algoritması geliştirilmiştir. Bu cevapların pratikte benimsenmesi halinde futbol takımlarında başarının artması ve sağlık harcamalarının azaltılması beklenmektedir.

### 1.5. Tezin Yapısı

Bu tez, yapay zeka kullanılarak sporcu termal görüntülerinden kas bölgelerinin segmentasyonu ve yaralanmaların tespitine yönelik bir çalışmayı kapsamaktadır. Tez kapsamında öncelikle, kaynak araştırması bölümünde sporcu yaralanmalarında yaralanma tespiti için kullanılan yöntemlere değinilmiştir. Ardından, bu yöntemlerle görüntülenen yaralanmalar ve bu yaralanmaların yapay zeka kullanılarak tespitine yönelik gerçekleştirilen çalışmalara detaylı bir şekilde yer verilmiştir.

Materyal ve yöntem bölümünde futbolcu termal görüntülerini içeren veri seti hakkında bilgi verilmiştir. Bu bölümde görüntülemesi yapılan futbolcular ile ilgili bilgiler, kullanılan termal kamera ve çekim prosedürü detaylı bir şekilde açıklanmıştır. Materyal ve yöntemin ilerleyen kısımlarında ise sırası ile termal görüntülerden kas bölgesi segmentasyonu ve yaralanmaların sınıflandırılması için kullanılan yöntemlere değinilmiştir. Son olarak da bu segmentasyon ve sınıflandırma yönteminin başarısını ölçmek için kullanılan performans ölçütlerine yer verilmiştir.

Araştırma sonuçları ve tartışma bölümünde bu tez kapsamında yapılan çalışmaların detayları ve sonuçları ele alınmıştır. Bu bölümde ilk olarak termal görüntülerden kas yaralanmalarının tespiti ve bu yaralanmaların rehabilitasyon süreçlerinin izlenmesine yönelik termografi kullanımı üzerine yapılan tıbbi doğrulama çalışmaları açıklanmıştır. İkinci aşamada ise futbolcu alt ekstremitte termal görüntülerinden kas bölgelerinin derin öğrenme yöntemleri ile segmentasyonu üzerine yapılan çalışmalara değinilmiştir. Son olarak ise segmente edilmiş kas bölgelerindeki yaralanmaların derin öğrenme yöntemleri ile tespiti üzerine gerçekleştirilen çalışmalara

yer verilmiştir (Ergene ve diğ., 2020; Bayrak ve diğ., 2021c; 2021b; 2021a; 2023; Ergene ve diğ., 2023; Bayrak ve diğ., 2024; Ergene ve diğ., 2024).


Sonuçlar ve öneriler kısmında ise tez kapsamında yapılan çalışmalarından elde edilen bulgulara ve bu bulguların performans kriterlerine göre karşılaştırmalarına değinilmiştir. Bu bulgular ışığında, tezin çıktılarının literatüre sağladığı katkılar değerlendirilmiş ve elde edilen sonuçlara dayanarak gelecekte yapılabilecek çalışmalara ilişkin öneriler sunulmuştur. Son olarak bu çalışmanın kullanılabileceği uygulama alanları ve yaygın etkisine yer verilmiştir.



## 2. KAYNAK ARAŞTIRMASI

### 2.1. Sporcu Yaralanmalarında Kullanılan Metotlar

Profesyonel futbol takımları için yaralanmalar, en büyük sorunlardan biri olarak öne çıkmaktadır. Bu durum, aynı zamanda kulüplerin başarısını doğrudan etkileyen en önemli faktörlerden biridir. Yaralanma sayısı ve oyuncuların kaçırılan maç sayısı arttıkça, kulübün başarı oranı önemli ölçüde azalmaktadır (Eliakim ve diğ., 2020). Amerikan futbol ligi MLS’de yapılan bir çalışmaya göre, bu yaralanmaların yaklaşık %75’i alt ekstremitelerde (Şekil 2.1) görülürken, özellikle %30’u hamstring bölgesini de kaplayan uyluk bölgesinde meydana gelmiştir (Forsythe ve diğ., 2022). Bu yaralanmaların iyileşmesi ortalama 22 ila 50 gün arasında sürmektedir (Jiang ve diğ., 2022; Chang ve diğ., 2024; Everett ve diğ., 2024).



**Şekil 2.1.** Segmentasyon ve yaralanma tespiti için belirlenmiş 9 ana kas bölgesine ayrılmış alt ekstremité görüntüsü.

Bu yaralanmalar genellikle antrenman sırasında kasların aşırı kullanımından kaynaklanmaktadır. Yapılan çalışmalara göre, oyuncunun antrenman yoğunluğu arttıkça performansının da olumlu yönde gelişmesi, bu durumu daha karmaşık bir hale getirmektedir. Bu nedenle, futbol kulüpleri ve fizyoterapistler, oyunculara daha fazla

antrenman yükü vermeyi hedeflemektedir (Fadhil ve diğ., 2024). Ancak antrenman sırasında oluşabilecek yaralanmaların önüne geçmek için oyuncuyu gözlemlemenin ve kas problemlerini erken evrede tespit etmenin bir yolunu aramaktadırlar. Bunun için kas gücünü ölçmek veya yorgunluğu tespit etmek amacıyla kreatin kinaz testleri, izokinetik cihazlar, USG, BT, röntgen veya MRG gibi metotlar yaygın olarak kullanılmaktadır (Crema ve diğ., 2015). Fakat bu yöntemlerin bazı sınırlamaları bulunmaktadır. Örneğin, kreatin kinaz testleri beslenme farklılığı, yaş, kas kütlesi gibi bireysel farklılıklar nedeniyle kesin sonuç vermeyebilir ve kas hasarını erken evrede tespit etmekte yetersiz kalabilmektedir (Mirenayat ve diğ., 2024). Ultrasonografi ve röntgen gibi yöntemler ise yüzeysel veya kemik odaklı görüntüleme sağladığı için derin doku analizinde sınırlı kalmaktadır (Crema ve diğ., 2015). Bu gibi sınırlamalar göz önünde bulundurulduğunda, kullanılan yöntemlerin etkinliği, uygulama zorlukları, bireysel farklılıklar ve teknolojik sınırlamalar nedeniyle değişkenlik gösterebilmektedir. Bundan dolayı yaralanmaların tespit edilmesi, yaralanma derecesinin ölçülmesi ve rehabilitasyon sürecinin planlanması amacıyla pek çok çalışma gerçekleştirilmiştir (Gaines ve Talbot, 1999; Crema ve diğ., 2016; dos Santos Bunn ve diğ., 2020; Isern-Kebshull ve diğ., 2020; Ergene ve diğ., 2023; Bayrak ve diğ., 2024; Chang ve diğ., 2024; Ergene ve diğ., 2024; Everett ve diğ., 2024; Fadhil ve diğ., 2024; Martínez Serrano, 2024).

### **2.1.1. Ultrasonografi Kullanımı**

Ultrasonografi (USG), insan kulağının duyma eşiğinin üzerinde, genellikle 2 ila 12 megahertz (MHz) aralığında frekansa sahip yüksek frekanslı ses dalgalarını kullanarak görüntü oluşturan bir tıbbi görüntüleme yöntemidir (Lucas ve diğ., 2014). Tıbbi ultrason, bu ses dalgalarını vücudun içine yönlendirerek organların, dokuların ve damarların yapısını incelemek amacıyla kullanılmaktadır. Bir ultrason cihazında, ses dalgaları vücuda gönderilir ve bu dalgalar dokulara çarparak geri döner. Geri dönen bu dalgalar, cihaz tarafından yakalanılarak görüntüye dönüştürülür. Bu yöntem, özellikle hamilelik takibi, karın içi organların incelenmesi, kalp ve damar yapısının görüntülenmesi ve sporcu kas yaralanmalarının incelenmesinde yaygın olarak kullanılmaktadır (Szabo, 2013).

USG'nin avantajları incelendiğinde güvenli, ağrısız ve MRG gibi diğer görüntüleme metotlarından daha kolay kullanılabilir olması, taşınabilir olması ve daha

az maliyetli olması muskuloskeletal (kas-iskelet sistemi) ultrasonografi üzerine yapılan çalışmaların artmasına sebep olmuştur (Jacobson ve van Holsbeeck, 1998). Kas-iskelet sistemi üzerine yürütülen USG araştırmalarında ise Young ve arkadaşları quadriceps kası genişliğinin USG ile ölçümünü gerçekleştirmişlerdir (Young ve diğ., 1980). Yine 80'li yıllarda Fornage ve arkadaşları 120 üst seviye atlette kas travmalarının tespitinde USG kullanarak %84 başarıya ulaşmışlardır (Fornage ve diğ., 1983). USG ile kas-iskelet sistemi yaralanmalarına yönelik çalışmalar, 20. yüzyılın son çeyreğinden itibaren hız kazanmış ve günümüze kadar teknolojinin gelişmesiyle birlikte daha da derinleşmiştir. Bu dönemin sonunda, USG'nin akut ve kronik diz yaralanmalarının değerlendirilmesindeki rolü incelenmiş ve diz yaralanmalarında diğer görüntüleme yöntemlerine alternatif olabileceği ortaya konulmuştur. (Ptasznik, 1999). Günümüze yaklaştıkça Petersen ve arkadaşları 50 futbol takımının katıldığı çalışmada akut hamstring kas hasarının büyüklüğü ile yaralanmadan sonraki iyileşme süresindeki ilişkiyi USG ile incelemişlerdir (Petersen ve diğ., 2014). USG'nin tendon üzerindeki incelemelerde kullanıldığı çalışmalara örnek olarak ise Rosengarten ve arkadaşlarının Avustralya futbol liginde gerçekleştirdiği araştırma verilebilir. Yapılan değerlendirmede bir maçlık oyun yükünün aşıl tendonu üzerinde bıraktığı etki başarılı bir şekilde USG ile incelenerek mikrotravmaların bu yöntem ile izlenebileceği ortaya koyulmuştur (Rosengarten ve diğ., 2015). Sartorius kası üzerine yapılan bir vaka çalışmasında ise USG kullanımı ile intramüsküler (kas içi) yırtıkların tespit edilebileceği gözlemlenmiştir (Malherbe, 2019).

Tüm bu çalışmalar ve sahip olduğu avantajlar doğrultusunda, ultrasonografi (USG), diğer tıbbi görüntüleme yöntemleri arasında önemli bir yer edinmiş olup, günümüzde kas yaralanmalarının tespiti için yaygın bir şekilde kullanılmaktadır. Ancak sahip olduğu tüm bu avantajların yanında USG'nin kas yaralanmalarında kullanımını sınırlayan dezavantajları da bulunmaktadır (Peetrons, 2002). USG kullanımında alanında uzman bir operatöre bağımlı olunması görüntüleme sonuçlarının operatörün deneyimine ve becerisine göre değişiklik göstermesine sebebiyet vermektedir. USG yüzeysel kaslarda başarılı sonuçlar vermesine karşın derin kas gruplarında görüntülemelerde zorluklar çıkarabilmektedir. USG, kaslardaki yüzeysel yapıları görüntülemelerde başarılı olsa da kas dokuları arasındaki daha ince detayları ve bağ dokusu, sinir ya da tendon gibi yapılarda ayrıntılı incelemede sınırları bulunmaktadır. Özellikle küçük çaplı yaralanmalar ya da mikrotravmalar ultrasonla gözden

kaçabilmektedir. Akut yaralanmalarda USG başarılı olurken eski veya kronik yaralanmalarda başarı oranı düşmektedir.

### 2.1.2. Bilgisayarlı Tomografi Kullanımı

Bilgisayarlı Tomografi (BT), vücudun iç yapılarının detaylı kesitsel görüntülerini oluşturmak için X-ışınları ve bilgisayar teknolojisinin sentezlendiği bir tıbbi görüntüleme yöntemidir. BT taramaları, X-ışını tüpünün vücudun etrafında dönmesi ve çeşitli açılardan X-ışınları göndererek bu ışınların dokulardan geçerken nasıl değiştiğini ölçmesi prensibine dayanmaktadır. Bu veriler, bilgisayar tarafından işlenerek vücudun kesit görüntüleri (tomogramlar) oluşturulur. Böylece, vücudun iç yapıları üç boyutlu bir görünüm kazanır ve organlar, kemikler, kaslar, kan damarları gibi çeşitli yapılar ayrıntılı şekilde incelenebilir (Marshall, 1976).

Bilgisayarlı tomografi (BT), sahip olduğu çeşitli avantajlar sayesinde tıbbi görüntüleme alanında sıkça tercih edilen bir yöntemdir. BT'nin en ince ayrıntıya kadar detaylı kesitsel görüntülemelere imkan sunması en büyük avantajlarından biridir. Bunun yanında organlar, kas-iskelet sistemi, yumuşak doku ve kan damarları gibi farklı dokuları aynı anda görüntüleyebilmesi, kısa tarama süresi, üç boyutlu görüntüleme imkanı, invaziv olmayan ağrısız bir metot olması ve yüksek doğruluk oranı gibi pek çok avantajları da bulunmaktadır (Hsieh ve Flohr, 2021). Bu avantajlarından dolayı futbol takımlarınca kas ve iskelet sistemi yaralanmalarının incelenmesi için kullanılmaktadır. Futbol takımlarını yakından ilgilendiren alt ekstremité yaralanmalarına yönelik çalışmalara örnek olarak Brandser ve arkadaşlarının yaptıkları araştırma gösterilebilir. Bu çalışmada konvansiyonel radyolojik görüntüleme yöntemlerinden BT ve MRG ile incelenen hamstring kasında BT aracılığıyla şişlik, hematoma oluşumu ve kas liflerinin yırtılması gibi değişiklikler gözlenmiş ve BT'nin, özellikle kas yırtıklarının boyutunu ve lokalizasyonunu değerlendirmede faydalı bir araç olabileceği sonucuna varılmıştır (Brandser ve diğ., 1995). BT ile kaslar üzerine yapılan bir diğer çalışmada ise BT ve USG kullanılarak yaşlılardaki kas yapısı incelenerek karşılaştırma yapılmıştır. Sonuç olarak da BT'nin de kas analizinde USG gibi başarılı bir metot olduğu sonucuna varılmıştır (Sipilä ve Suominen, 1993). BT ve MRG'nin birlikte kullanıldığı çalışmalar da gerçekleştirilmiştir. Örneğin Speer ve arkadaşlarının yürüttüğü çalışmada adductor, hamstring, quadriceps ve triceps surae kas yaralanmalarının görüntülenmesi gerçekleştirilmiş ve iki görüntüleme metodunun da benzer sonuçları verdiği

gözlemlenmiştir (Speer ve diğ., 1993). Yine bu iki metodun beraber kullanıldığı diğer bir çalışmada ise futbolcularda sık görülen rektus femoris kas yaralanmasının görüntülemesi gerçekleştirilerek yaralanmaların tespiti ve derecelendirilmesi yapılmıştır (Hughes IV ve diğ., 1995).

Literatürde yapılan çalışmalardan da görülebileceği üzere, BT'nin kas yaralanmalarının tespitindeki başarısı hem tek başına hem de diğer görüntüleme metotları ile birlikte kullanılarak doğrulanmıştır. Bununla birlikte, diğer görüntüleme yöntemleri de farklı avantajlar sunmakta ve belirli durumlarda daha etkili sonuçlar sağlayabilmektedir. Bu sebeplerle, güncel çalışmalarda BT ile birlikte USG, MRG gibi yöntemlerin bir arada kullanıldığı çok yönlü yaklaşımlar benimsenmektedir. Ancak tüm bu avantajlarının ve başarılarının yanında, BT çeşitli dezavantajlar da barındırmaktadır. Bu dezavantajlar hem hasta sağlığı hem de teşhis süreci açısından bazı sınırlamalar veya olumsuz etkiler yaratabilmektedir. En önemli dezavantajlarından biri görüntülemenin X-ışınlarına dayanması sebebiyle yüksek radyasyon maruziyetine sebebiyet vermesidir. Bu radyasyon dozu ise klasik bir röntgen filminden çok daha yüksek seviyelere ulaşmaktadır. Özellikle kemik yapıları görüntülemeye çok başarılı olan BT, yumuşak dokuların görüntülenmesinde yetersiz kalabilmektedir. Özellikle kas yırtıkları, bağ dokusu veya kas liflerindeki mikrotravmalar gibi ince yapısal değişikliklerde MRG BT'ye kıyasla daha detaylı ve başarılı sonuçlar vermektedir. BT, kas yaralanmalarında yalnızca kasların anatomik yapısını gösterebilmektedir, ancak kasların fonksiyonel durumunu, yani hareket sırasında nasıl çalıştığını veya yaralanmanın kasın işlevini nasıl etkilediğini değerlendirmede başarısız olmaktadır. Örneğin, kas kasilması veya hareket sırasında oluşan dinamik hasarların tespitinde USG daha başarılı sonuçlar vermektedir. BT yüzeysel kas yapılarını görüntülemeye daha başarılı olduğundan dolayı derin kas gruplarını görüntülemeye sınırlamalara sahiptir. Bundan dolayı obez hastalarda ya da kalın kas yapısına sahip sporcularda derin kas dokularında meydana gelen hasarların tespitinde zorluk yaşanabilir. Bu gibi dezavantajlarının yanında BT çekimleri maliyetli olmaktadır. Radyasyon maruziyeti ve maliyet sebebi ile de rehabilitasyon boyunca sürekli çekim imkanı da bulunmamaktadır.

### **2.1.3. Manyetik Rezonans Görüntüleme (MRG) Kullanımı**

Manyetik Rezonans Görüntüleme (MRG), güçlü manyetik alanlar ve radyo dalgaları kullanarak vücudun iç yapılarının detaylı görüntülerini elde eden bir tıbbi

görüntüleme yöntemidir. Yumuşak dokular, kemikler, eklemler, sinir sistemi ve organların ayrıntılı incelenmesini sağlar ve diğer yöntemlere kıyasla çok yüksek çözünürlük sunmaktadır. MRG, protonların manyetik alan altındaki davranışlarını ölçerek çalışmaktadır ve elde edilen sinyaller bilgisayar tarafından işlenerek kesitsel görüntüler oluşturulur (Kuperman, 2000). Özellikle yumuşak dokuların, tümörlerin, yaralanmaların ve patolojik süreçlerin yüksek çözünürlükle değerlendirilmesinde kullanılmaktadır.

MRG sahip olduğu çeşitli avantajlar nedeniyle tıbbi görüntüleme alanında sıkça tercih edilen bir yöntemdir. MRG'nin en büyük avantajlarından biri, yumuşak doku, beyin, kaslar, bağlar, sinirler ve organların yüksek çözünürlükte detaylı görüntülenmesini sağlamasıdır. Bunun yanında, iyonlaştırıcı radyasyon içermemesi, farklı dokuları üç boyutlu ve net bir şekilde görüntüleyebilmesi, invaziv olmayan ağrısız bir yöntem olması ve fonksiyonel görüntüleme imkanı sunarak beyin gibi organların işlevsel durumunu inceleyebilmesi gibi pek çok avantajı da bulunmaktadır. Bu avantajlarından dolayı MRG futbol kulüpleri tarafından da sıkça kullanılmaktadır. Kas yaralanması üzerine yapılan detaylı bir çalışmada Shelly ve arkadaşları kaslarda darbe kaynaklı çürükler, kesikler, üç farklı derecede zorlanmaya bağlı yaralanmalar, kompartman sendromu, ödem ve tendon yaralanmasının MRG ile görüntülenmesi üzerine çalışmışlardır. Bu çalışmada bahsi geçen bütün kas problemlerinde tanı, yaralanmanın şiddetini değerlendirme ve tedaviye yanıtın izlenmesinde MRG'nin başarılı bir sonuç verdiği gözlemlenmiştir (Shelly ve diğ., 2009). Futbol özelinde yapılan bir diğer çalışmada ise akut hamstring yaralanması olan 275 futbolcuda MRG ile kasın anatomik bölgesinin yaralanma süresine olan etkisi incelenmiştir (Crema ve diğ., 2016). Isern-Kebschull ve arkadaşları tarafından yapılan bir çalışmada ise, sporla ilişkili alt ekstremitte kas yaralanmalarını tanı ve tedavi süreçlerinde kullanılan MRG teknikleri incelenmiştir. Sporcuların alt ekstremitelerinde meydana gelen kas yaralanmalarının sınıflandırılması ve değerlendirilmesi amacıyla bir desen tanıma yaklaşımı benimsenmiştir. Kas yaralanmalarının patofizyolojisi, yaralanma mekanizmaları ve MRG bulguları detaylı olarak ele alınmış, her yaralanma tipine özgü MRG bulguları tanımlanmıştır. Yazarlar, kas zedelenmelerinin yanı sıra kas zorlanmaları, kas yırtıkları ve kas-iskelet sisteminde yaygın olarak görülen diğer yaralanma türlerinin MRG ile nasıl görüntülendiğini incelemişlerdir. Sonuç olarak, MRG'nin spor kaynaklı kas yaralanmalarının tanısında, şiddetinin belirlenmesinde ve tedaviye yanıtın izlenmesinde güvenilir ve etkili bir yöntem olduğu vurgulanmıştır.

(Isern-Kebschull ve diğ., 2020). Basketbolcularda alt ekstremite yaralanmalarının MRG ile incelenmesi üzerine yapılan bir diğ er arařtırmada ise yazarlar mevcut ve geliřmekte olan MRG yöntemlerinin bu tür yaralanmaların teřhis, yaralanma derecesinin belirlenmesi ve tedavi sürecinin izlenmesindeki etkinliđini incelemiřtir. Özellikle, kas-iskelet sistemi yaralanmaları, tendon ve bađ zedelenmeleri, menisküs lezyonları ve stres kırıkları gibi yaygın problemler detaylı bir řekilde deđerlendirilmiřtir. Yazarlar, ileri teknikler arasında difüzyon ađırlıklı görüntüleme, T2 haritalama, doku elastografi ve dinamik MRG gibi yöntemlerin kullanımını tartıřmıřtır. Sonuç olarak, bu geliřmiř MRG tekniklerinin yaralanmaların daha dođru ve erken teřhis edilmesinde, sporcuların rehabilitasyon süreçlerinin izlenmesinde ve bireysel tedavi planlarının oluřturulmasında önemli katkılar sađladığı vurgulanmıřtır (Rubin ve diğ., 2024). Yapılan çalıřmalarda da görüldüğü üzere MRG yaralanmaların tanısının koyulması, yaralanma řiddetinin belirlenmesi ve rehabilitasyon sürecinin planlanarak spora dönüř kararının verilmesi konusunda bařarılı bir řekilde kullanılmaktadır.

Tüm bu üstünlüklerine ve sunduđu avantajlara karřın, MRG'nin bazı sınırlamaları da bulunmaktadır. Bu dezavantajlar hem hasta sađlığı hem de teřhis süreci ađısından bazı sınırlamalar veya olumsuz etkiler yaratabilmektedir. MRG'nin en önemli dezavantajlarından biri, tarama süresinin uzun olmasıdır. MRG taramaları diđer görüntüleme metotların kıyasla daha uzun sürdüğünden, hastaların hareketsiz kalması zor olabilmekte ve bu durum özellikle klostrofobi olan hastalar veya çocuklar için problem yaratabilmektedir. Ayrıca, MRG güçlü manyetik alanlar kullanır ve bu nedenle vücutta metalik implantlar (örneğin, kalp pili, ortopedik implantlar) bulunan hastalar için uygun olmayabilir. MRG, yumuřak dokuları görüntülemede çok bařarılı olmasına karřın, kemik yapılarının görüntülenmesinde BT kadar etkili deđildir. MRG'nin bir diđer dezavantajı ise maliyetidir; diđer görüntüleme sistemlerine kıyasla daha pahalıdır ve her yerde erişilebilir olmayabilir. Bunların yanı sıra, MRG dinamik görüntüleme yapamadığı için kasların fonksiyonel durumunu hareket halinde izlemek yerine daha çok statik görüntüler sađlamaktadır.

#### **2.1.4. Kan Testleri ve İzokinetik Cihaz Kullanımı**

Kreatin kinaz testi, kandaki kreatin kinaz (KK) adı verilen bir enzimin seviyesini ölçen bir kan testidir. KK, kasların enerji üretiminde önemli bir rol oynayan bir enzimdir ve genellikle kas hücrelerinde, kalp kasında ve beyinde bulunur. Kas hücreleri

hasar gördüğünde veya parçalandığında, KK kana salınır ve kandaki seviyeleri yükselir. Bu nedenle, KK testi, kas hasarını veya kas hastalıklarını tespit etmek için kullanılır (Cabaniss, 1990). KK seviyesindeki yükselişe kalp krizi, ağır antrenman kas yaralanmaları ve kas zedelenmeleri neden olmaktadır. Bundan dolayı futbolcularda antrenmana bağlı yorgunluk ve kas yaralanmaları için KK seviyesindeki yükselişler incelenmektedir (Brancaccio ve diğ., 2007). KK testi başarısı kanıtlanmış sonuçlar vermesine karşın ölçüm sonuçları kişiden kişiye değişiklik gösterebilmektedir. Bunun nedeni her kişideki kas kütesinin ve metabolizmasının farklılıklarıdır. Aynı zamanda KK testleri hangi kasta nasıl bir hasarın olduğunu belirleyememekte olup sadece genel bir kas yıkımı olduğu bilgisini vermektedir. Geçirilmiş bir ameliyat, kullanılan bir ilaç veya alkol tüketimi de bu düzeylerde değişikliğe sebep olmaktadır.

İzokinetik test, kasların kuvvet ve dayanıklılığını ölçmek amacıyla yapılan bir değerlendirme yöntemidir. Bu test, bir kişinin belirli bir eklem veya kas grubunun maksimum kasılma gücünü ve kasılma hızını sabit bir hızda ölçmeyi sağlar. İzokinetik dinamometre adı verilen özel bir cihaz kullanılarak yapılan bu testte, eklem belirlenen bir hızda hareket etmesine izin verilir ve test sırasında üretilen kuvvet, cihaz tarafından kaydedilir. İzokinetik test, sporcularda kas kuvvetini değerlendirmek, yaralanma sonrası kas dengesizliklerini ve güç kaybını tespit etmek için yaygın olarak kullanılmaktadır. Özellikle diz, omuz, kalça ve ayak bileği eklemlerinde kuvvet ölçümü yapılır. Bu sayede kas bölgesindeki hasarlar tespit edilebilmektedir (Moffroid ve diğ., 1969; Gaines ve Talbot, 1999). İzokinetik cihaz ile kas kuvveti ve dayanıklılığı objektif olarak ölçülür, bu da kas performansı hakkında kesin bilgi sağlar. Ancak izokinetik cihazlar oldukça maliyetli olabilmekte ve test zaman alabilmektedir.

### **2.1.5. Termal Görüntüleme Kullanımı**

Kızılötesi termografinin temelleri, kızılötesi (infrared) radyasyon adı verilen elektromanyetik spektrumun keşfine dayanmaktadır. 1800 yılında Sir William Herschel, güneş ışığını bir prizma yardımıyla ayırırken, kırmızı ışığın ötesindeki görünmeyen bölgeden sıcaklık artışları tespit etmiştir. Bu olay, kızılötesi radyasyonun ilk keşfi olarak kabul edilmektedir ve termografinin temelini oluşturmaktadır (Meola, 2012). 19. yüzyılın sonunda doğru Samuel Langley, “bolometre” adı verilen bir cihaz geliştirmiştir. Bu cihaz, kızılötesi radyasyonu tespit edebilmekteydi ve sıcaklık değişimlerine duyarlıydı (Langley, 1880). Bu buluş, daha sonraki termal görüntüleme

cihazlarının geliştirilmesine ilham vermiştir ve bu dönemden sonra daha gelişmiş termal görüntüleme cihazları üretilmeye başlanmıştır. 1960'lara doğru tıp alanında kullanılmaya başlanan termografi hakkında yapılmış ilk çalışmalardan birinde meme kanserinin termal görüntülerden tespit edilmesine dayanmaktaydı (Lawson, 1956).

Termal görüntüleme, sporculardaki yaralanmaların tespitinde ve değerlendirilmesinde son dönemlerde popülerleşen non-invaziv, güvenli ve hızlı bir görüntüleme yöntemidir (Sillero-Quintana ve diğ., 2021). Yaralanmalar, özellikle kas ve eklem yaralanmaları, iltihaplanmalar veya aşırı kullanıma bağlı travmalar gibi durumlar, yaralanmanın olduğu bölgede inflamasyona eden olmaktadır, bu durum da genellikle bölgesel sıcaklık değişikliklerine yol açmaktadır. Termal görüntüleme bu sıcaklık değişimlerini tespit ederek yaralanmaların erken teşhisinde ve iyileşme sürecinin izlenmesinde kullanılabilmektedir (dos Santos Bunn ve diğ., 2020).

Termografinin tıbbi görüntülemede sıkça tercih edilmesinin en önemli avantajlarından biri, cilt yüzeyindeki sıcaklık farklılıklarını non-invaziv bir şekilde tespit ederek, kas-iskelet sistemi yaralanmaları, iltihaplanmalar ve dolaşım bozuklukları gibi durumları hızlı ve etkili bir şekilde değerlendirebilmesidir. Bunun yanında, iyonlaştırıcı radyasyon içermemesi, herhangi bir fiziksel temas gerektirmemesi ve ağrısız bir yöntem olması da termografinin önemli avantajlarındanıdır. Ayrıca, tedavi sürecinin takibi sırasında sıcaklık değişikliklerini izleyerek iyileşme sürecini değerlendirme imkanı sunmaktadır. Bu avantajlarından dolayı termografi, futbol kulüpleri ve spor hekimliği alanında da sıklıkla kullanılmaktadır. Kas yaralanmalarının tespitinde termografi kullanımına örnek olarak Verderber ve arkadaşlarının yürüttükleri bir çalışmada termografinin sporcuların kas hasarlarını tespit etmedeki etkinliğini değerlendirmiştir. Çalışmada, farklı sıcaklık ölçüm yöntemlerinin karşılaştırılması ve en uygun metriklerin belirlenmesi hedeflenmiştir. Çalışma sonucunda termografinin potansiyel kas yaralanmalarının tespitinde ve önlenmesinde kullanılabileceği görülmüştür (Verderber ve diğ., 2024). Diğer bir çalışmada ise diz osteoartritinin tespitinde termografi kullanımı üzerine çalışılmıştır. Diz sıcaklığındaki artışın osteoartrit ile bağlantısını kanıtlayan bu çalışmanın sonucunda termografinin osteoartrit tanısında ve takibinde önemli bir araç olabileceği vurgulanmıştır (Petrigna ve diğ., 2024). Sartorius kas yaralanmalarına odaklanan bir diğer çalışmada ise termografinin egzersiz etkisi altında kas yaralanmalarının tespitindeki rolü üzerine çalışılmıştır. Egzersiz öncesi ve on dakikalık bisiklet programı sonrası çekilen termografi görüntülerinde sartorius kasında asimetrik bulgular elde edilmiştir. MRG ile de

doğrulaması yapılan kas bölgesinde sartorius kas yaralanması izlenmiştir. Bu çalışma sonucunda kas yaralanması tespitinde sadece dinlenmiş halde değil hafif egzersiz programının termografi ile kas yaralanmasının erken tespitinde faydalı olduğu gözlenmiştir (Bayrak ve diğ., 2024). Majano ve arkadaşlarının yaptıkları bir çalışmada antrenman yükünün ve çevresel koşulların profesyonel futbolcuların kasları üzerine etkilerini incelemek için termografi kullanmışlardır. Araştırma sonucunda çevresel koşulların öneminin incelenen spesifik kas grubuna bağlı olarak değiştiğini göstermiştir. Özellikle hamstring kas grubunun, çevresel koşullara verdiği tepkinin daha önemli olduğu bir bölge olduğu görülmüştür. Bu çalışma termografinin, çevresel streslerin sporcu vücudu üzerindeki etkilerini değerlendirme potansiyelini ve bu teknolojinin antrenman ve yaralanma önleme programlarında nasıl kullanılabileceğini vurgulamıştır (Majano ve diğ., 2024). Başka bir çalışmada ise Alvrdu ve arkadaşları profesyonel erkek futbolcularda 30-15 aralıklı fitness testi sırasında ve sonrasında cilt sıcaklığındaki akut değişimleri incelemişlerdir. Araştırmada, yorgunluk ve antrenman yükünün cilt sıcaklığı ve termal yanıt üzerindeki etkilerini değerlendirmeyi amaçlamışlardır. Bulgularda, futbolcuların fiziksel yüklenme sonrası vücut termal yanıtlarının incelenebileceği vurgulanmış ve termografinin sporcularda performans ve yaralanma risk yönetimindeki değerini ortaya koyulmuştur (Alvrdu ve diğ., 2024). Futbolcuların yaralanmalarının termografi ile incelenmesine yenilikçi bir yaklaşım sunan bir çalışmada ise thermopixelgraphy olarak adlandırılan yeni bir yöntem tanıtılarak alt ekstremitte cilt sıcaklıklarının analizinde termografinin kullanımı ele alınmıştır. Bu yöntem termografinin mevcut uygulamalarını geliştirerek daha detaylı bir piksel tabanlı analiz sağlamıştır. Sonuçlarda sporcuların fiziksel yüklenmelerine bağlı olarak oluşan termal değişimlerin daha net bir şekilde ortaya koyulduğu görülmüştür. Bu çalışma, termografinin gelişmiş bir versiyonunu tanıtarak, sporcularda cilt sıcaklık analizi ve yaralanma yönetimi için yeni bir standart oluşturma potansiyeline sahip olduğu vurgulanmıştır. Araştırmacılar özellikle kas yaralanmalarını öngörme ve sporcu sağlığını izleme için yenilikçi bir araç sunmaktadır (de Andrade Fernandes ve diğ., 2024). Farklı spor dallarındaki profesyonel sporcuların diz eklemiindeki termal desenlerin incelendiği bir çalışmada, diz eklemiinde termografinin kullanımı değerlendirilmiştir. Araştırmada, sağ ve sol diz arasında oluşabilecek sıcaklık asimetrisi gözlemlenerek, spor dalına özgü yüklenme farklılıklarının ve yaralanma risklerinin analizi yapılmıştır. Çalışmanın sonuçlarında, termografinin diz eklemi çevresindeki termal normalliklerin belirlenmesinde ve termal dengesizliklerin

yaralanma riski ile ilişkilendirilmesinde etkili bir yöntem olduğu vurgulanmış ve spor dalına özel olarak normal sıcaklık değerlerinin belirlenmesinin, yaralanma önleme ve rehabilitasyon süreçlerinde daha etkin bir yönetim sağlayabileceği görülmüştür (de Rezende ve diğ., 2024). Futbolcularda rehabilitasyon süreçlerinin termografi ile incelendiği bir diğer çalışmada ise ön çapraz bağ yaralanmasından sonra rehabilitasyon sürecinde futbolcuların oyuna dönüş kriterlerini belirlemek için termografinin kullanımını değerlendirilmiştir. Araştırmada kas bölgelerinin sıcaklık asimetrisi gözlemlenerek rehabilitasyon sırasında iyileşmenin hızı ve süreci incelenmiştir. Sonuçlarda termografinin, ön çapraz bağ yaralanmalarının rehabilitasyon sürecinde kas iyileşmesini ve yüklenme dengesini değerlendirmek için etkili bir yöntem olduğu vurgulanmış ve termografinin klinik ölçümlerle birlikte kullanıldığında rehabilitasyon sürecinin daha etkin yönetilmesine olanak tanıdığı görülmüştür (Escamilla-Galindo ve diğ., 2025). Literatürde yapılan çalışmalar incelendiğinde termografinin sporcularda kas yaralanmalarının erken evre tespiti, yaralanmanın incelenmesi ve rehabilitasyon sürecinin yönetilmesi için etkin bir araç olarak önce çıktığı görülmektedir. Çalışmaların sonuçları göz önüne alındığında termografinin gelecekte profesyonel spor kulüpleri tarafından yaralanma tespit ve yönetiminde birincil yöntemlerden biri olarak benimseneceği ve yaygın bir şekilde kullanılacağı öngörülmektedir.

Diğer görüntüleme metotlarına kıyasla maliyet, hızlı çekim, non-invaziv olması, radyasyon içermemesi ve birçok alanda kullanılabilir olması gibi avantajlarının yanında termografinin dezavantajları da bulunmaktadır. Derin kas bölgelerini görüntülemeye zorluk yaşaması ve çevresel ısı farkından etkilenmesinden dolayı çekim prosedürünün düzenlenmesi ve gerekirse hafif antrenman programı eklenmesi gerekebilmektedir. Ayrıca çekimlerin değerlendirilmesine bir operatöre bağımlı olması yani görüntünün yorumlanmasında bir eğitim gerektirmesi termografinin dezavantajlarından biridir. Bu nedenle termografik görüntülerin yorumlanmasında, özellikle yaralanma tespitinde yapay zeka destekli algoritmalar geliştirilmeye başlanmıştır.

## **2.2. Sporcu Yaralanmalarının Yapay Zeka ile Tespiti**

Termografinin futbolcularda kas yaralanmasının erken evre tespiti, aktif yaralanmanın izlenmesi ve rehabilitasyon takibinde kullanılabilir bir metot olduğu güncel çalışmalarca kanıtlanmaktadır. Ancak termografinin dezavantajları göz önüne alındığında spor kulüpleri özelinde düşünmek de gerekmektedir. Kızılötesi görüntülerin

yorumlanması için bir operatör tercihen fizyoterapist veya spor hekimi görev almaktadır. Bu konuda özel uzmanlığa sahip operatörlerin bulunması kulüpler için sorun teşkil edebilmektedir. Ek olarak bu operatörün görüntüleri incelemesi esnasında hata yapma payı da bulunmaktadır. Ayrıca bir futbol kulübündeki futbolcuların sayısı göz önüne alındığında her bir futbolcunun antrenman öncesi ve sonrası görüntülerini tek tek izlenmesi ve yorumlanması çok vakit almaktadır. Bundan dolayı yapay zeka algoritmaları ile termografi görüntülerinden yaralanmaların tespiti için karar destek mekanizmaları geliştirilmeye başlanmıştır.

Termografi ve yapay zeka ile oluşturulan karar destek mekanizmaları üzerine birçok çalışma yapılmaktadır. Yapılan bir derleme çalışmasında termografinin tıbbi görüntüleme alanında nasıl kullanıldığını ve bu teknolojinin hastalıkların, yaralanmaların veya enfeksiyonların erken teşhisine nasıl destek sağlayabileceğini ele almaktadır. Çalışmada, yapay zeka destekli kızılötesi görüntüleme teknolojilerinin, sıcaklık farklılıklarını tespit ederek vücuttaki anormal bölgeleri hızlı ve doğru bir şekilde analiz edebildiğini vurgulanmaktadır. Yapay zeka algoritmalarının, termal görüntülerdeki ince değişiklikleri tespit etmede insan gözünden daha hassas olabileceği, bunun da erken teşhis ve tedavi sürecini hızlandırabileceği gösterilmiştir. Çalışmada ayrıca, yapay zeka ile desteklenen bu teknolojinin tanı doğruluğunu artırma, maliyetleri düşürme ve sağlık hizmetlerinin kalitesini yükseltme potansiyeline dikkat çekilmektedir. Sonuç olarak, yapay zeka ve termografinin tıbbi görüntülemeye entegrasyonunun, tıpta daha geniş uygulama alanları yaratabileceği öne sürülmektedir (Hix ve diğ., 2024). Termografinin tıbbi uygulamalarda destek olarak kullanıldığı çalışmalardan bir tanesinde ise alt ekstremitte bölgelerinden otomatik olarak kas segmentasyonu yapan bir algoritma geliştirilmiştir. Yapılan çalışmada U-Net, FPN, Linknet ve PSPNet kullanılarak kas bölgeleri başarıyla segmente edilmiş ve bu metotların kıyaslamaları yapılmıştır (Ergene ve diğ., 2023). Diğer bir çalışmada ise termal görüntülerden kas aktivitesi ve yorgunluğu tespit etmek için denetimli makine öğrenmesi metotları kullanılmıştır. Çalışmada kullanılan makine öğrenimi yöntemleri olarak lineer regresyon (LR), support vector regressor (SVR) (lineer ve Gaussian çekirdekleri ile), ensemble regressors ve Gaussian process regression (GPR) yöntemleri yer almaktadır. Çalışma, bu yöntemlerle kızılötesi termal görüntüleme verilerini analiz ederek kas aktivitesi ve yorgunluğunu tahmin etmeyi amaçlamaktadır. Araştırma, bu regresyon modellerinin kas aktivitesi takibinde ve yorgunluk düzeylerinin tahmininde başarılı olabileceğini ortaya koymuştur (Perpetuini ve diğ., 2023). Lopez ve

arkadaşlarının yaptığı çalışmada ise termografinin biyomedikal araştırmalarda kullanılmasına yönelik derin öğrenme tabanlı bir algoritma tanıtmışlardır. Bu çalışma, manuel analizlerin genellikle karşılaştırılmaz ve tekrarlanamaz sonuçlar verdiğini, ayrıca egzersiz sırasında kan damarlarına bağlı termal radyasyon desenlerini tanımlayamadığını vurgulamaktadır. Çalışmada koşma sırasında elde edilen termal görüntülerden DeepLabV3+ ile gerekli kas bölgeleri segmente edilmiş, daha sonra uyarlanmış bir U-Net kullanılarak segmente edilen bölgelerden venöz ve arteriyel damarların segmentasyon işlemi yapılmıştır. Geliştirilen algoritmanın manuel test setlerinde sağ ve sol baldır için yüksek doğruluk elde ettiği gözlemlenmiştir (Andrés López ve diğ., 2024). Benzer bir çalışmada ise futbolcuların termal görüntülerinden yaralanma tespiti gerçekleştiren bir algoritma geliştirilmiştir. Geliştirilen algorithmada U-Net kullanılarak futbolcu alt ekstremitte görüntülerinden hamstring kas bölgesinin segmentasyonu yapılmış, daha sonra da Densenet, Resnet, EfficientNet ve VGG derin öğrenme metotları kullanılarak segmente edilmiş kas bölgesinde yaralanma sınıflandırması işlemi gerçekleştirilmiştir. Geliştirilen bu algoritma sistemi, yüksek doğrulukla çalışarak futbolcuların kas yaralanmalarını erken teşhis etmeyi ve tedavi süreçlerini iyileştirmeyi amaçlamaktadır. Çalışmada, termal görüntüleme ve derin öğrenme entegrasyonunun sporcuların yaralanma yönetimi için önemli bir potansiyel sunduğunu vurgulanmaktadır (Ergene ve diğ., 2024).

Yapılan çalışmalarda da görüldüğü üzere termografik görüntüleme sisteminin yapay zeka ile birlikte kullanılması futbol kulüpleri ve fizyoterapistler için oldukça faydalı birer karar destek mekanizması olarak kullanılmaktadır. Bu sayede spor hekimlerinin erken evre yaralanma tespiti, rehabilitasyon takibi ve tedavi sonlandırma süreçlerinde kararlarını kolaylaştırmaktadır. Sahip olduğu avantajlara rağmen, yapay zeka ve termografinin birlikte kullanımı, segmentasyon ve sınıflandırma doğruluğunu artırma konusunda bazı zorluklar barındırmaktadır. Özellikle, veri setlerinin dengesiz ve sınırlı olduğu durumlarda sınıflandırma performansının düşmesi bu zorluklar arasında dikkat çekmektedir. Bu tez kapsamında da farklı metotlar kullanılarak bu zorluklara çeşitli çözümler getirilmiştir. Sonraki bölümde ise bu metotların detaylarına yer verilmiştir.

### 3. MATERYAL VE YÖNTEM

Futbolcu termal görüntülerinden yapay zeka kullanılarak yaralanma tespiti yapılırken, veri setinin büyüklüğü, veri sınıflarının dengesi ve kas segmentasyonu ile sınıflandırması için kullanılan yöntemler gibi pek çok değişken dikkate alınması gereken önemli unsurlar arasındadır. Bu tez kapsamında kas segmentasyonu ve yaralanma sınıflandırması için farklı yöntemler kullanılmış olup, termal verilerde dengesiz ve yetersiz veri seti probleminin çözümü için yaklaşımlar geliştirilmiştir.

Bu bölümde öncelikle veri setinde görüntüleri bulunan futbolculara ait bilgiler, veri sayısı, görüntüleme için kullanılan termal kamera ve çekim protokolüne yer verilmiştir. Daha sonra, futbolcularda yapay zeka ile kas segmentasyonu ve yaralanma tespiti için kullanılan derin öğrenme yöntemleri ve bu yöntemlerin performanslarının değerlendirilmesi için kullanılan ölçütlerin detayları ele alınmıştır.


#### 3.1. Veri Seti

Çalışma için gerekli verilerin toplanması için KTO Karatay Üniversitesi Tıp Fakültesi Etik Kurulundan 24 Nisan 2020 tarih ve 2020/005 sayılı kararı ile etik kurul onayı alınmış olup EK-1’de sunulmuştur. Çalışma süresince profesyonel Türkiye Süper Lig futbolcuları alt ekstremitte termal görüntüleri toplanmıştır. Tüm oyuncular için termal görüntüleme, egzersiz öncesi ve sonrasında yapılmıştır. Sağlıklı oyuncular, egzersiz kapsamında rutin antrenman programlarını tamamlamışlardır. Aktif yaralanması bulunan oyunculara ise, yaralı kasın korunmasını sağlamak amacıyla yalnızca yüklenme olmaksızın bisiklet egzersizi uygulanmış ve bu egzersiz sonrası kasın harekete geçirilmesine yönelik görüntüleme verileri toplanmıştır. 2 sezon boyunca yapılan çekimlerde toplamda 43 profesyonel futbolcudan 320 termal görüntü kaydedilmiştir. Termal görüntülerde gerçekleştirilen segmentasyon ve sınıflandırma işlemleri için yakınlaştırma, döndürme, yatay ve dikey çevirme gibi veri arttırım teknikleri kullanılarak 720 görüntü oluşturulmuştur. Görüntüsü alınan futbolculara ait sosyodemografik bilgiler Çizelge 3.1’de detaylı olarak verilmiştir.


**Çizelge 3.1.** Futbolcuların sosyodemografik bilgileri

| Oyuncu | Pozisyon           | Yaş | Boy   | Dominant Ayak | Hamstring Kası  |
|--------|--------------------|-----|-------|---------------|-----------------|
| 1      | Kaleci             | 32  | 1,90m | Sol Ayak      | Sağlıklı        |
| 2      | Kaleci             | 35  | 1,86m | Sağ Ayak      | Aktif Yaralanma |
| 3      | Kaleci             | 21  | 1,91m | Sağ Ayak      | Sağlıklı        |
| 4      | Kaleci             | 29  | 1,86m | Sağ Ayak      | Sağlıklı        |
| 5      | Kaleci             | 32  | 1,88m | Sağ Ayak      | Sağlıklı        |
| 6      | Kaleci             | 27  | 1,95m | Sağ Ayak      | Sağlıklı        |
| 7      | Stoper             | 26  | 1,85m | Sol Ayak      | Sağlıklı        |
| 8      | Stoper             | 36  | 1,86m | Sağ Ayak      | Aktif Yaralanma |
| 9      | Stoper             | 23  | 1,85m | Sağ Ayak      | Sağlıklı        |
| 10     | Stoper             | 27  | 1,84m | Sağ Ayak      | Sağlıklı        |
| 11     | Stoper             | 28  | 1,85m | Sağ Ayak      | Sağlıklı        |
| 12     | Stoper             | 28  | 1,84m | Sağ Ayak      | Aktif Yaralanma |
| 13     | Stoper             | 32  | 1,85m | Sağ Ayak      | Aktif Yaralanma |
| 14     | Stoper             | 31  | 1,92m | Sol Ayak      | Aktif Yaralanma |
| 15     | Stoper             | 30  | 1,86m | Sağ Ayak      | Sağlıklı        |
| 16     | Sol Bek            | 31  | 1,80m | Sol Ayak      | Sağlıklı        |
| 17     | Sol Bek            | 30  | 1,80m | Sol Ayak      | Aktif Yaralanma |
| 18     | Sağ Bek            | 29  | 1,75m | Sağ Ayak      | Aktif Yaralanma |
| 19     | Sağ Bek            | 32  | 1,77m | Sağ Ayak      | Sağlıklı        |
| 20     | Sağ Bek            | 28  | 1,79m | Sağ Ayak      | Sağlıklı        |
| 21     | Sağ Bek            | 24  | 1,73m | Sağ Ayak      | Aktif Yaralanma |
| 22     | Defansif Orta Saha | 24  | 1,79m | Sağ Ayak      | Sağlıklı        |
| 23     | Defansif Orta Saha | 27  | 1,94m | Sağ Ayak      | Aktif Yaralanma |
| 24     | Defansif Orta Saha | 22  | 1,73m | Sağ Ayak      | Sağlıklı        |
| 25     | Defansif Orta Saha | 28  | 1,83m | Sağ Ayak      | Sağlıklı        |
| 26     | Defansif Orta Saha | 19  | 1,80m | Sağ Ayak      | Sağlıklı        |
| 27     | Merkez Orta Saha   | 23  | 1,77m | Sağ Ayak      | Sağlıklı        |
| 28     | Merkez Orta Saha   | 27  | 1,72m | Sağ Ayak      | Sağlıklı        |
| 29     | Ofansif Orta Saha  | 26  | 1,83m | Sağ Ayak      | Aktif Yaralanma |
| 30     | Ofansif Orta Saha  | 27  | 1,91m | Sol Ayak      | Sağlıklı        |
| 31     | Ofansif Orta Saha  | 30  | 1,75m | Sağ Ayak      | Aktif Yaralanma |
| 32     | Sol Kanat          | 24  | 1,74m | Sağ Ayak      | Aktif Yaralanma |
| 33     | Sol Kanat          | 24  | 1,76m | Sağ Ayak      | Sağlıklı        |
| 34     | Sol Kanat          | 17  | 1,73m | Sağ Ayak      | Sağlıklı        |
| 35     | Sol Kanat          | 18  | 1,76m | Sağ Ayak      | Sağlıklı        |
| 36     | Sağ Kanat          | 25  | 1,84m | Sol Ayak      | Aktif Yaralanma |
| 37     | Sağ Kanat          | 27  | 1,76m | Sol Ayak      | Sağlıklı        |
| 38     | Sağ Kanat          | 18  | 1,76m | Sağ Ayak      | Sağlıklı        |
| 39     | Forvet             | 30  | 1,87m | Sağ Ayak      | Sağlıklı        |
| 40     | Forvet             | 22  | 1,87m | Sol Ayak      | Sağlıklı        |
| 41     | Forvet             | 32  | 1,89m | Sağ Ayak      | Sağlıklı        |
| 42     | Forvet             | 30  | 1,83m | Sağ Ayak      | Sağlıklı        |
| 43     | Forvet             | 18  | 1,88m | Sol Ayak      | Sağlıklı        |

Görüntü alma işlemi Infratec VarioCAM® termal kamera ile gerçekleştirilmiştir. Görüntüleme 21°C sabit sıcaklıkta bir odada yapılmıştır. Görüntüleme işlemi gerçekleştirilmeden önce oyuncu, odada 5 dakika boyunca bekletilmiştir. Çekimler normal anatomik pozisyonda ön ve arka olacak şekilde 2 metre mesafeden gerçekleştirilmiştir. Her futbolcu için görüntüler antrenman öncesinde ve sonrasına alınmıştır. Görüntüleme sistemi ve alınan alt ekstremité termal görüntü örneği Şekil 3.1 ve Şekil 3.2’de verilmiştir.



Şekil 3.1. Oluşturulan termografik görüntüleme sistemi.



Şekil 3.2. Örnek alt ekstremité termal görüntüsü (arkadan)

Amerikan Futbol Ligi (MLS)'de yapılan bir çalışmada, yaralanmaların yaklaşık %75'inin alt ekstremitelerde meydana geldiği, bu oran içinde %30'unun hamstring bölgesini de içeren uyluk bölgesinde gerçekleştiği rapor edilmiştir (Forsythe ve diğ., 2022). Bu bulgular doğrultusunda, çalışmada hamstring kas bölgesine odaklanılmış ve bu bölgedeki yaralanmalar incelenmiştir. Hamstring bölgesinin diğer yaralanmalara kıyasla daha sık yaşanması ve veri toplama açısından kolaylık sağlaması, bu tercihin temel nedenlerini oluşturmaktadır. Çizelge 3.1'de de görüldüğü üzere 30 sağlıklı, 13 hamstring kas yaralanması bulunan görüntüleri elde edilmiştir. Yaralanmaların doğrulanması MRG görüntüleme, kreatin kinaz ve izokinetik testler ile profesyonel spor hekimleri ve fizyoterapistler tarafından yapılmıştır.

### 3.2. Yöntemler

Termal görüntüleri alınan futbolcularda kas segmentasyonu ve yaralanma tespiti için çeşitli derin öğrenme algoritmaları kullanılmıştır. Bu derin öğrenme algoritmalarının eğitim ve test süreçleri için kullanılan donanım ve özellikleri Çizelge 3.2'de verilmiştir. Algoritmaların başarı kriterleri ile ilgili detaylı bilgi performans değerlendirme ölçütleri kısmında verilmiştir (Bölüm 3.3).

**Çizelge 3.2.** Derin öğrenme için kullanılan donanım ve eğitim bilgileri

|                       |                                                |
|-----------------------|------------------------------------------------|
| Kütüphane             | Tensorflow-2.10 & Keras                        |
| CUDA Versiyonu        | 11.2                                           |
| GPU                   | RTX 2060                                       |
| Kayıp Fonksiyonu      | İkili Çapraz Entropi                           |
| Öğrenme Oranı         | 0,001                                          |
| Performans Kriterleri | IoU, F1, Duyarlılık, Kesinlik, Doğruluk, Kayıp |

Segmentasyon ve sınıflandırma işlemleri için yeni modeller eğitilmiştir. Segmentasyon ve sınıflandırma işlemi sırasında en iyi başarıyı elde etmek için eğitimde 5-katlı çapraz doğrulama prosedürü kullanılmıştır.

#### 3.2.1. Termal Görüntülerden Kas Segmentasyonu


Termal görüntüler kullanılarak yapay zeka ve makine öğrenimi teknikleriyle yaralanma tespitine yönelik literatürde birçok çalışma bulunmaktadır (Jin ve diğ., 2013;

Bardhan ve diğ., 2022; Trejo-Chavez ve diğ., 2022; Ergene ve diğ., 2023; Alvrdu ve diğ., 2024; Ergene ve diğ., 2024; Hix ve diğ., 2024; Voinea ve diğ., 2024). Aynı şekilde, termal görüntüleme yöntemiyle yaralanmaların iyileşme sürecinin izlenmesine ilişkin çalışmalar da dikkat çekmektedir (dos Santos Bunn ve diğ., 2020; Bayrak ve diğ., 2021c; 2021b; 2023; de Andrade Fernandes ve diğ., 2024; Rubin ve diğ., 2024). Bu çalışmalara, kaynak araştırması bölümünde ayrıntılı olarak yer verilmiştir. Termal görüntülerden yapay zeka ile yaralanma tespiti üzerine yapılan çalışmaların birçoğunda, sınıflandırma işlemi ilgili kas bölgesi (Region of Interest - ROI) üzerinde gerçekleştirilmiştir. Başka bir deyişle, ROI sınıflandırıcı sisteme kullanıcı tarafından verilmiş ve sistem, yaralanma bölgesinin doğrudan ilgi merkezinde olmasını sağlayacak şekilde bu bölge üzerinde sınıflandırma yapılmıştır. Ancak, gerçek hayatta kas bölgelerinin el ile verilmesi, zorlayıcı ve zaman alıcı olmaktadır. Literatürdeki bu problemin önüne geçmek için, termal görüntülerden kas segmentasyonunun otomatik olarak yapılması gerekmektedir.

Tez çalışmasında Üst adductor, quadriceps rectus, quadriceps vastus, vastus medialis, patella, gastrocnemius ve soleus, tibialis anterior ve fibularis, ayak bileği ve ayak olarak belirtilen 9 kas bölgesini alt ekstremitte termal görüntülerinden segmente etmek için U-Net, PSPNet, LinkNet ve FPN derin öğrenme modelleri kullanılmıştır.

### 3.2.1.1 U-Net

U-Net, 2015 yılında Ronneberger ve ekibi tarafından biyomedikal görüntü segmentasyonu üzerine önerilmiş bir derin öğrenme modeli olup evrimsel sinir ağı (ESA) tabanlı bir derin öğrenme modelidir (Ronneberger ve diğ., 2015). U şeklinde simetrik bir mimariye sahip olan bu modelin temel amacı görüntüleri piksel seviyesinde sınıflandırmak ve istenilen nesne veya bölgelerin segmentasyonunu yapmaktır. Mimarinin kodlayıcı (encoder) ve çözücü (decoder) olmak üzere iki ana bölümü bulunmaktadır. Kodlayıcı kısmı, giriş görüntüsünü alarak özellik haritaları oluşturmakta ve görüntüyü sıkıştırmaktadır. Çözücü kısmı ise bu özellik haritalarını kullanarak segmentasyon haritası şeklinde yeniden yapılandırmaktadır (Du ve diğ., 2020). Şekil 3.3'te de görülen aşağı doğru inen kodlayıcı kısmı ve yukarı doğru çıkan çözücü kısmından oluşan iki bölümün simetrik yapısı ve modelin veri akışı "U" şekline benzetildiğinden dolayı bu özelliği modele U-Net ismini kazandırmaktadır (Ronneberger ve diğ., 2015).



Şekil 3.3. U-Net Mimarisi (Ergene ve diğ., 2023)


Yukarıdan aşağı inen kodlayıcı bölüm, görüntünün özelliklerini öğrenmek amacıyla giriş görüntüsünün çözünürlüğünü her adımda küçülten bir yapıya sahiptir. Kodlayıcı, ardışık olarak düzenlenmiş konvolüsyon katmanları ve maksimum havuzlama (max pooling) katmanlarından oluşur. Burada her bir adımda görüntü boyutu küçülürken, özellik sayısı artmaktadır. Böylece model, görüntüde daha karmaşık ve soyut özellikleri öğrenebilme yetisine sahip olmaktadır. Aşağıdan yukarı çıkan çözücü bölümde ise, kodlayıcıda öğrenilen özellik haritalarını kullanarak görüntüyü segmentasyon haritası şeklinde yeniden oluşturmaya çalışılır. Bu bölümde, özellik haritalarını genişletmek ve orijinal boyutuna geri döndürmek için çeşitli işlemler yapılmaktadır. Havuzlama ve konvolüsyon ile küçültülen görüntüler yukarı örnekleme (up sampling) ile orijinal boyutlarına getirilir. Kodlayıcı bölümünün konvolüsyon katmanlarından gelen özellik haritaları yukarı örneklenen haritalarla birleştirme katmanlarında birleştirilerek görüntünün detaylarının korunmasına yardımcı olur. Çözücüde her bir yukarı örnekleme adımıyla çözünürlük artarken, aynı zamanda özellik haritası sayısı azaltılır. Sonuç olarak, tam boyutlu bir segmentasyon haritası elde edilir (Falk ve diğ., 2019).

U-Net'in biyomedikal görüntü segmentasyonunda tercih edilmesine neden olan avantajlarından biri, kodlayıcı kısmından gelen özellik haritalarını yukarı örnekleme katmanının çıkışı ile birleştiren birleştirme katmanı sayesinde detayların korunmasını sağlaması ve bu da yüksek çözünürlüklü segmentasyon haritalarının oluşturulmasına olanak tanınmasıdır. U-Net, biyomedikal veri setlerinin genellikle sınırlı miktarda olması

nedeniyle, az veri ile başarılı sonuçlar verebilecek şekilde tasarlanmıştır. Bu model, az veriyle dahi iyi performans sergileyebilmekte ve sınırlı veriyle yüksek başarı oranları elde edebilmektedir. Bir diğer önemli avantajı ise işlem hızıdır. Hızlı yapısı, modeli gerçek zamanlı veya hızlı işlem gerektiren uygulamalarda oldukça pratik hale getirmektedir (Falk ve diğ., 2019). Bu özellikleri, U-Net'i medikal görüntü segmentasyonunda güçlü ve tercih edilen bir model olarak öne çıkarmaktadır.

### 3.2.1.2 Piramit Sahne Ayırıştırma Ağı (PSPNet)

Piramit sahne ayırıştırma ağı (PSPNet), görüntü segmentasyonunda, özellikle sahne ayırıştırma (scene parsing) görevinde üstün performans sağlamak amacıyla Zhao ve arkadaşları tarafından geliştirilmiş bir derin öğrenme modelidir (Zhao ve diğ., 2017). Sahne ayırıştırma, bir görüntüdeki her pikselin sahnede bulunan objelere göre belirli bir kategoriye atanması anlamına gelmektedir. Bu da görüntüdeki nesneleri ve alanları tanımlamak için oldukça önemlidir. Ancak bu görev, sıradan segmentasyondan daha zordur çünkü sahnede bulunan bütün objelerin piksel ölçeğinde ayrıştırılması gerekmektedir. Bundan dolayı sahne ayırıştırma farklı ölçeklerdeki nesneler ve karmaşık sahne yapısı nedeniyle zorluklar içermektedir. PSPNet, bu zorlukların üstesinden gelmek için piramit havuzlama (pyramid pooling) adı verilen özel bir yöntem kullanarak sahne ayırıştırmada daha yüksek doğruluk elde etmek amacıyla geliştirilmiştir. PSPNet'in mimarisi, farklı ölçeklerdeki özellikleri görüntüden yakalayarak sahnenin genel yapısını öğrenmek için tasarlanmıştır. Bu mimari, giriş görüntüsünden bir evrişimsel ağ ile çıkarılan özellikleri bir piramit yapısı içinde toplar ve bu sayede görüntünün en düşük seviyeli özelliklerinden en yüksek seviyeli özelliklerine kadar görüntüyü farklı ölçeklerde anlamlandırır. PSPNet'in temel bileşenleri Şekil 3.4'de verildiği üzere; evrişimsel ağ içeren özellik çıkarıcı ağ (backbone), görüntünün özelliklerini ölçeklendiren piramit havuzlama modülü (pyramid pooling module) ve sınıflandırıcı son katman (final classifier) olarak üç ana bölümden oluşmaktadır (Ergene ve diğ., 2023).




İlk katmanda genellikle ResNet gibi güçlü bir evrimsel sınır ağı (ESA) mimarisi kullanılmaktadır ve bu mimari görüntüdeki özelliklerin çıkarılması işlevini görmektedir. Bu özellik çıkarıcı ağ, görüntüdeki yüksek seviyeli özellikleri çıkarır ve görüntüdeki nesnelerin, yapısal ayrıntıların ve sahne bileşenlerinin birer temsilini oluşturur. Özellik çıkarıcı katman, ResNet veya buna benzer daha derin bir model olarak seçilebilmektedir. Bu mimarinin derin katman yapısı, daha ayrıntılı ve karmaşık özelliklerin çıkarılmasını sağlamakta, bu da modelin sahne ayrıştırma performansını arttırmakta ve özellik çıkarıcı katman olarak ResNet gibi derin mimarilerin tercih edilmesine sebep olmaktadır (He ve diğ., 2016; Durmuş ve diğ., 2024). PSPNet'in en önemli bileşeni, ikinci katmanı olan piramit havuzlama modülüdür. Çünkü bu modül mimarinin görüntüdeki çok ölçekli özellikleri yakalamasını sağlayan ana yapısıdır. Görüntüdeki farklı boyut ve mesafelerdeki nesnelerin etkili bir şekilde tanımlanmasını sağlamak için 1x1, 2x2, 3x3 ve 6x6 olmak üzere dört farklı ölçek seviyesinde havuzlama işlemi yapmaktadır (Zhao ve diğ., 2017). 1x1 havuzlama kısmı tüm görüntüyü tek bir hücreye indirgemesi sayesinde global özellikleri yakalamak için kullanılmaktadır. Mimarinin bu kısmı, görüntünün genel sahne yapısını ve bağlamını öğrenmektedir. Diğer ölçekler ise orta ve küçük ölçeklerdeki nesnelerin özelliklerini çıkarmaya yönelik daha ayrıntılı havuzlama işlemleri yapmaktadır. Farklı ölçeklerdeki havuzlamalar sayesinde, sahnenin hem genel hem de detaylı bilgilerini içeren zengin özellik haritaları elde edilmektedir. Piramit havuzlama ile elde edilen bu detaylı özellik haritaları daha sonra yukarı örnekleme katmanı ile yeniden ölçeklendirilir ve birleştirme işlemi ile tüm özellik haritaları birleştirilerek bir bütün özellik haritası elde edilir. Bu sayede mimari hem küçük hem de büyük nesneleri aynı anda değerlendirebilir ve sahne hakkında çok yönlü bilgi edinilir. PSPNet'in son bileşeni olan son sınıflandırıcı katman ise piramit havuzlama modülünden gelen özellik haritalarını konvolüsyon işlemi ile sınıflandırarak her pikselin hangi sınıfa ait olduğunu tahmin eder. Yani bu katman

havuzlanmış ve birleştirilmiş özellik haritalarını kullanarak her pikseli ilgili sınıfa atar.

PSPNet, segmentasyon işlemlerinde sıkça tercih edilmesini sağlayan güçlü bir ağ yapısına sahiptir. İlk önemli avantajı, ağ yapısındaki farklı ölçeklerde özellik çıkarabilen piramit havuzlama modülünü kullanarak sahnedeki nesnelerin boyutu ve mesafesi fark etmeksizin hepsini aynı anda tanıyabilmesidir. Bu sayede, görüntüdeki tüm nesneleri kapsamlı bir şekilde sınıflandırarak farklı boyutlarda bulunan nesneleri daha doğru bir şekilde tanımlayabilmektedir. PSPNet, bir pikseli sınıflandırırken yalnızca o pikselin değerine değil, çevresindeki diğer piksel ve nesnelerin özelliklerine de bakarak bağlam bilgisi kullanmaktadır. Bu bağlam bilgisi sayesinde, nesneler yalnızca tek başlarına değil, sahnenin diğer kısımlarıyla olan ilişkileriyle birlikte anlamlandırılabilir. Ayrıca özellik haritalarını birleştirerek nesnelerin sınırları daha ince ve keskin bir şekilde tespit edebilmektedir. Tüm bu avantajları, PSPNet'i görüntü segmentasyonunda güçlü bir araç haline getirmekte ve çeşitli endüstriyel ve bilimsel uygulamalarda etkili bir model olarak öne çıkarmaktadır.

### 3.2.1.3 LinkNet

LinkNet, görüntü segmentasyonunu hızlı ve verimli bir şekilde gerçekleştirmek için Chaurasia ve arkadaşları tarafından tasarlanmış hafif bir derin öğrenme modelidir (Chaurasia ve Culurciello, 2017). Bu model, nesneleri piksel seviyesinde sınıflandırarak görüntüyü anlamlandırmayı hedeflemektedir. LinkNet, gerçek zamanlı segmentasyon gerektiren ve düşük hesaplama gücüyle çalışması gereken otonom araçlar, mobil cihazlar ve güvenlik sistemleri gibi uygulamalarda kullanılmak üzere geliştirilmiştir (Deoli ve diğ., 2024). LinkNet, Şekil 3.5'te görüldüğü üzere simetrik bir mimariye sahiptir. Kodlayıcı (encoder) ve çözücü (decoder) olmak üzere iki ana bölümden oluşmaktadır (Chaurasia ve Culurciello, 2017).



Şekil 3.5. LinkNet Mimarisi (Chaurasia ve Culurciello, 2017)


Kodlayıcı bölümü, görüntünün farklı özelliklerini çıkarmak amacıyla bir dizi evrişimsel katman kullanmaktadır. Kodlayıcıda her bir katmanda giriş görüntüsünden çıkarılan özellikler, boyutları küçültülerek daha özet bir temsil haline getirilir. LinkNet, genellikle ResNet gibi derin öğrenme modellerini temel almaktadır ve bu modellerin derin katman yapısından yararlanarak yüksek seviyeli özellikler öğrenmektedir. ResNet mimarisinde her bir konvolüsyon katmanı, sıfırdan öğrenmek yerine önceki katmandan gelen bilgiyi kullanarak yeni özellikler öğrenir. Artık (residual) bağlantılar sayesinde model, derinlik arttıkça oluşabilecek gradyan kaybını en aza indirerek daha verimli öğrenmeye olanak sağlar (He ve diğ., 2016). Kodlayıcı, her bir katmanda özellik çıkarırken aynı zamanda boyut küçültme yani aşağı örnekleme (down-sampling) işlemiyle görüntüyü özetler. Bu işlemler, nesnelerin daha karmaşık özelliklerini tanımak için önem arz etmektedir. Her bir katmanda örnekleme ile görüntü boyutu küçülürken görüntüden elde edilen özellik sayısı artmaktadır. Bu yapı, modelin daha derin ve soyut özellikleri öğrenmesine olanak tanımaktadır. Kodlayıcıdan gelen görüntüden çıkarılan özellik haritaları, çözücü kısmında segmentasyon haritası oluşturmak için yeniden yapılandırılır. Çözücü bölümde, özellik haritaları her katmanda yukarı örnekleme (up-sampling) işlemiyle büyütülerek orijinal görüntü boyutuna geri getirilir. Bu bölümde, kodlayıcı bölümde kullanılan konvolüsyon işleminin aksine transpoze konvolüsyon (transposed convolution) işlemini kullanır. Bu işlem sayesinde özellik haritaları yukarı doğru örneklenerek detay seviyesini artırır ve yüksek çözünürlüklü bir segmentasyon haritası oluşturulur. U-Net gibi modellerde birleştirme katmanı ile de yapılan atlama bağlantıları (skip connections) LinkNet'te toplama işlemi ile gerçekleştirilmektedir. Bu bağlantılar kodlayıcı ve çözücü katmanları arasında bilgi aktarımı sağlar. Atlama bağlantıları, kodlayıcı bölümde çıkarılan özellik haritalarını çözücü katmanda aynı seviyedeki katmanlarla doğrudan bağlantılı hale getirir. Bu sayede, kodlayıcıdan gelen özellik haritaları çözücüdeki aynı katmanla toplanır ve segmentasyon haritası için

detaylı bilgi sağlanmış olur. Bu sayede görüntüdeki küçük nesnelerin ve ince ayrıntıların bilgileri korunmuş olur.

LinkNet'in segmentasyon işlemlerinde sıklıkla kullanılmasının sebeplerinden biri hızlı ve verimli ağ yapısının sağladığı avantajıdır. Düşük hesaplama maliyetine sahip hafif bir model olmasından dolayı sınırlı donanıma sahip cihazlarda verimli bir şekilde kullanılabilmektedir. Bu özelliği sayesinde, otonom araçlardan mobil cihazlara kadar birçok uygulamada gerçek zamanlı görüntü segmentasyonu ihtiyacının karşılanmasını sağlamaktadır. LinkNet, kodlayıcı ve çözücü katmanlar arasındaki atlama bağlantıları sayesinde görüntüdeki küçük nesnelerin ve ince detayların segmentasyon haritasında korunmasını mümkün kılarak, kodlayıcı bölümden çözücüye bilgi aktarımı yaparak daha hassas segmentasyon sonuçları vermesine olanak tanır. Ayrıca, LinkNet'te atlama bağlantılarının toplama işlemiyle yapılması, modelin hesaplama yükünü azaltmakta ve daha hızlı bir bilgi aktarımı sağlamaktadır. Bu avantajları sayesinde, LinkNet segmentasyon gerektiren görevlerde verimli bir araç haline gelmekte ve özellikle insansız hava araçları, güvenlik sistemleri ve medikal görüntüleme gibi birçok alanda öne çıkmaktadır.

#### 3.2.1.4 Özellik Piramit Ağı

Özellik piramit ağı (ÖPA, İng. kısaltması FPN), farklı ölçeklerde nesne algılama ve görüntü segmentasyonunda üstün performans sağlamak amacıyla Lin ve arkadaşları tarafından geliştirilmiş bir derin öğrenme modelidir (Lin ve diğ., 2017). FPN, özellikle görüntüde bulunan farklı boyutlardaki nesneleri aynı anda algılayabilme kabiliyeti sayesinde çok ölçekli görüntü analizi gerektiren uygulamalarda yaygın olarak tercih edilmektedir. Bu model, evrimsel sinir ağı (ESA) tabanlı bir mimaridir ve nesneleri farklı çözünürlüklerde anlamlandırmak için özellik haritalarını farklı ölçeklerde piramidal bir yapıda birleştirir ve her seviyede özellik bilgisi toplanmasını sağlar (Kim ve diğ., 2018). FPN'in temel yapısında özellik çıkarıcı ağ (backbone), aşağı ve yukarı örnekleme katmanları ve lateral bağlantılar olmak üzere 4 temel yapı bulunmaktadır (Şekil 3.6).



Şekil 3.6. FPN Mimarisi (Ergene ve diğ., 2024)

FPN aslında ESA tabanlı bir ağ olduğundan görüntüdeki özelliklerin elde edilmesi için temelinde özellik çıkarıcı bir ağ bulunmaktadır. Pratik kullanımında diğer ağlarda da olduğu gibi genelde ResNet gibi güçlü bir ESA mimarisi tercih edilmektedir (He ve diğ., 2016; Seferbekov ve diğ., 2018). Bu ağ, görüntüdeki özellikleri çıkarmak amacıyla görüntüyü farklı seviyelerde işler ve her bir seviyede çeşitli özellik haritaları oluşturulmasına olanak tanır. Özellik çıkarıcı ağın katmanları, görüntüyü Şekil 3.6’da olduğu gibi farklı boyutlara indirger ve her katman, görüntünün belirli bir çözünürlük seviyesini temsil eder. Bu katmanlar, FPN’de bir piramit yapısı oluşturarak her seviyede farklı boyuttaki nesnelerin aynı anda tespit edilmesini sağlamaktadır. Aşağı örnekleme kısmı aslında özellik çıkarıcı ağın katmanlarında gerçekleşen klasik konvolüsyon işlemidir. Bu kısım görüntünün orijinal boyutunu konvolüsyon işlemi ile her bir katmanında küçültür ve her bir katmanda görüntünün özet bir temsilini oluşturur. Aşağı örnekleme yapılırken her katmandaki görüntü bir öncekinden daha düşük çözünürlüğe sahiptir, ancak her katmanda çıkarılan özellikler giderek daha derin ve daha anlamlı hale gelmektedir. Bu sayede ağ, görüntüdeki hem küçük nesnelerin hem de büyük yapıların özelliklerini ayırarak nesneleri aynı anda tespit edebilir. Yukarı örnekleme kısmı özellik çıkarıcı ağın son katmanından başlayarak yukarıya doğru devam eden bir süreçtir. Bu kısımda önceki aşağı örnekleme katmanlarında elde edilen daha düşük çözünürlükteki özellik haritaları yukarı örnekleme işlemiyle daha yüksek çözünürlüklü hale getirilir. Yukarı örnekleme işlemiyle, özellik çıkarıcı ağdan elde edilen düşük çözünürlüklü özellik haritaları giderek daha yüksek çözünürlüklere taşınarak daha kapsamlı bir segmentasyon haritası elde edilir. Bu sayede FPN sadece küçük veya

büyük nesneleri değil geniş sahneleri de etkili bir biçimde segmente edebilmektedir. Lateral bağlantılar, FPN'in en önemli özelliklerinden biridir. Bu bağlantılar, Şekil 3.6'daki özellik piramit ağında görüleceği üzere, aşağı örnekleme kısmındaki her bir katmandan çıkarılan özellik haritalarını yukarı örnekleme kısmındaki karşılık gelen seviyeye bağlanmasını sağlar. Bu bağlantılar, özellik haritalarının her bir seviyede birbirine eklenmesi veya birleştirilmesiyle yapılır ve görüntüdeki hem ayrıntılı bilgilerin hem de bağlam bilgisinin korunmasına yardımcı olur (He ve diğ., 2016). Lateral bağlantılar sayesinde, model farklı çözünürlüklerdeki özellik haritalarını tek bir piramidal yapıda toplar ve çok yönlü bir analiz yapmaya fırsat tanır. Bu bağlantılar sayesinde, yukarı örnekleme kısmında oluşturulan her bir özellik haritası, aşağı örnekleme kısmında karşılık gelen özellik haritasıyla birleşir ve çok ölçekli özelliklerin daha doğru bir şekilde öğrenilmesini sağlar.

FPN'in segmentasyon işlemlerinde sıkça tercih edilmesinin ardında çok yönlü piramidal ağ yapısı bulunmaktadır. FPN'in ilk önemli avantajı, piramidal ağ yapısındaki çoklu ölçeklerde özellik çıkarabilme yeteneği sayesinde sahnedeki nesnelerin boyutu ve mesafesi fark etmeksizin hepsini aynı anda tanıyabilmesidir. Bu sayede, görüntüdeki tüm nesneleri kapsamlı bir şekilde sınıflandırarak farklı boyutlardaki nesneleri daha başarılı bir şekilde tanımlayabilmektedir. Ayrıca, lateral bağlantılar sayesinde farklı çözünürlüklerdeki özellik haritalarını birleştirerek nesnelerin sınırlarının daha ince ve keskin bir şekilde tespit edilmesini sağlamaktadır. Tüm bu avantajları, FPN'i görüntü segmentasyonu ve nesne algılama alanında tercih edilen model haline getirmektedir.


### 3.2.2. Yaralanma Sınıflandırması için Kullanılan Yapay Zeka Yöntemleri

Futbol kulüplerinin performansını ve sürdürülebilir başarısını etkileyen kritik unsurlardan biri, futbolcuların yaralanmalarının doğru ve hızlı bir şekilde tespit edilmesidir. Bu alanda, araştırmacılar tıbbi görüntüleme yöntemlerini kullanarak yaralanmaların sınıflandırılması üzerine yoğun çalışmalar yapmaktadır. Özellikle, futbolcu termal görüntülerinden yapay zeka destekli yazılımların kullanımı, yaralanma tespiti ve yönetiminde giderek daha önemli bir rol oynamaktadır. Termal görüntülerden kas yaralanması sınıflandırması üzerine kullanılacak pek çok derin öğrenme metodu bulunmaktadır. Bu tez kapsamında yapılan çalışmada ise termal görüntülerden hamstring kas bölgesi yaralanmalarını tespit etmek için çok katmanlı Densenet, VGG,

ResNet, EfficientNet, Siyam ağırları, Prototip ağırları, Kolmogorov-Arnold Ağı metotları kullanılmıştır.

### 3.2.2.1. Densenet

DenseNet (Densely Connected Convolutional Network), derin öğrenme modellerinde daha verimli ve hızlı özellik çıkarımı sağlamak amacıyla Huang ve arkadaşları tarafından geliştirilmiş, güçlü bir ESA mimarisidir (Huang ve diğ., 2017). DenseNet'in temel yapısı, her katmandan gelen bilgiyi bir sonraki katmanla paylaşarak veri akışını güçlendirmekte ve bu sayede daha derin ağlarda öğrenme sürecini hızlandırmaktadır. Bu model, özellikle yüksek verimlilik gerektiren birçok görüntü işleme ve sınıflandırma uygulamalarında tercih edilmektedir. U-Net gibi segmentasyon odaklı mimarilerle benzerlik gösterse de DenseNet daha çok özellik çıkarımı ve sınıflandırma işlemleri için optimize edilmiştir. DenseNet'in literatüre kattığı yenilik, geleneksel ağlardan farklı olarak katmanları arasındaki bağlantıların yoğun şekilde kullanılmasıdır. Bu mimaride, her bir katman yalnızca kendinden önce gelen katmandan değil, kendinden önceki tüm katmanlardan gelen bilgiyi kullanır. Bu bağlantılar, yoğun bağlantılar (dense connections) olarak adlandırılmaktadır ve her bir katmanın çıkışını doğrudan sonraki tüm katmanlara bağlayarak gradyan kaybını önler. Bu yoğun bağlantılar sayesinde, model daha derin yapılarda bile gradyanların akışını kolaylaştırır ve daha iyi bir öğrenme performansı sağlar (Zhong ve diğ., 2020). DenseNet mimarisi giriş katmanı, yoğun bloklar (dense blocks), geçiş katmanları (transition layers), ve sınıflandırma katmanı olmak üzere dört ana bileşenden oluşmaktadır (Şekil 3.7).



Şekil 3.7. Densenet Mimarisi (Ergene ve diğ., 2024)

Giriş katmanı genellikle  $7 \times 7$  boyutunda bir konvolüsyon katmanı ile başlayan, giriş görüntüsünü alarak diğer katmanlarda özellik çıkarımı için gerekli bilgileri sağlayan katmandır. Daha sonra maksimum havuzlama katmanı kullanılarak özellik haritaları yoğunlaştırılır ve sonraki katmanlara geçiş yapılır. DenseNet'in karakteristik katmanı olan yoğun katmanlar birden fazla konvolüsyon katmanından oluşur ve her katman, kendisinden önce gelen tüm katmanlardan gelen özellik haritalarını giriş olarak alır. Böylece modelin her bir katmanda daha fazla özelliği yeniden kullanması sağlanır ve parametrelerin daha verimli bir şekilde kullanılmasına olanak tanınmış olur. Ayrıca katmanlar arasındaki yoğun bağlantılar, gradyanların daha iyi bir şekilde yayılmasını sağlar. Bu durum da gradyan kaybını (vanishing gradient problem) önler ve daha derin ağlarda daha iyi öğrenme performansı sağlanmış olur. Yoğun bloklar arasında bulunan geçiş katmanları ise, özellik haritalarını yoğunlaştırmak ve boyutlarını azaltmak için kullanılır. Geçiş katmanları genellikle  $1 \times 1$  konvolüsyon ve  $2 \times 2$  ortalama havuzlama (average pooling) katmanlarından oluşmaktadır.  $1 \times 1$  konvolüsyon katmanı, yoğun bloktan gelen özellik haritalarının sayısını azaltarak modelin hesaplama maliyetini düşürür, bu durum da modelin parametre sayısını azaltarak hesaplama yükünü hafifletir ve modelin aşırı derinleşmesini engeller (Liu ve Zeng, 2018). Ortalama havuzlama katmanı, görüntü boyutunu yarıya indirir ve böylece bir sonraki yoğun bloğa daha küçük, ancak daha yoğun özelliklerin geçiş yapmasını sağlar. Mimarinin son bölümü olan sınıflandırma katmanında ise önceki katmanlarda çıkarılan özellikleri sınıflandırmak için kullanılan bir sınıflandırma katmanı bulunmaktadır. Genellikle, bu bölümde küresel ortalama havuzlama (global average pooling) katmanı yer alır ve bu katmanda özellik haritalarının ortalaması alınarak her bir sınıf için bir çıkış değeri


üretir. Bu havuzlama işlemi de modelin parametre sayısını azaltarak genel hesaplama maliyetini düşürür (Huang ve diğ., 2017). Ardından, tam bağlantılı (fully connected) bir katman ve softmax aktivasyon fonksiyonu kullanılarak sınıflandırma yapılır ve modelin her bir sınıf için olasılık değerleri üretmesini sağlar (Zhang ve diğ., 2019). DenseNet-121, DenseNet-169 ve DenseNet-201 gibi farklı katman derinliklerine sahip, literatürde sıkça kullanılan versiyonları bulunmaktadır. Adlarından da anlaşılacağı üzere DenseNet varyasyonları sahip oldukları toplam katman sayısına göre isimlendirilmektedir. Örneğin, DenseNet-121'in 121 katmanı bulunmaktadır.

Yoğun bağlantılı katman yapısının sağladığı avantajları DenseNet'in sınıflandırma görevlerinde sıkça tercih edilmesine sebep olmaktadır. Bu avantajı, her katmanın kendisinden önce gelen tüm katmanlardan bilgi alabilmesini sağlayan yoğun bağlantılar sayesinde verimli özellik çıkarımı sağlamasıdır. Bu yoğun bağlantılar, modelin her bir katmanda daha fazla bilgiye erişmesine olanak tanıyarak, gradyan kaybını önler ve öğrenme sürecini hızlandırır. Ayrıca, özelliklerin yeniden kullanımı sayesinde model daha az parametreyle daha iyi genelleme yapabilir ve daha yüksek performans sergiler. Geçiş katmanları ise, özellik haritalarını yoğunlaştırarak modelin hesaplama yükünü azaltmakta ve daha kompakt bir yapı sunmaktadır. Tüm bu avantajları, DenseNet'i görüntü sınıflandırma ve nesne algılama alanlarında güçlü bir araç haline getirmektedir.

### 3.2.2.2. Görsel Geometri Grubu (GGG)

Görsel Geometri Grubu (İng. Kısaltması: VGG), görüntü sınıflandırma ve nesne tanıma görevlerinde yüksek performans sağlamak amacıyla geliştirilmiş ESA temelli bir mimaridir. En bilinen ve sıkça kullanılan versiyonları olan VGG-16 ve VGG-19, sırasıyla 16 ve 19 katman içermektedir. Bu ağ yapısı, özellikle basit, simetrik ve derin katman yapısı sayesinde yüksek doğruluk oranlarına ulaşılmasını sağlamaktadır. VGG, 2014 yılında ImageNet yarışmasında elde ettiği başarılar sayesinde popüler hale gelmiştir (Russakovsky ve diğ., 2015). VGG mimarisinde uygulanan birkaç temel katman bulunmaktadır. Bu modelde, Şekil 3.8'de görüldüğü üzere her bir konvolüsyon katmanı 3x3 filtreler ile yapılandırılmıştır ve her iki veya üç konvolüsyon katmanından sonra bir maksimum havuzlama katmanı bulunmaktadır. VGG mimarisinin derinliği, modelin çok sayıda özellik çıkarım katmanına sahip olmasına olanak sağlamaktadır. Bu sayede VGG, daha fazla özellik çıkarma işlemi

gerçekleştirerek karmaşık nesneleri tanımda başarılı hale gelmektedir (Simonyan, 2014).




Şekil 3.8. VGG Mimarisi (Ergene ve diğ., 2024)

VGG'nin giriş katmanı genellikle 224x224 piksel boyutunda ve üç kanallı (RGB) giriş görüntüsü alır ve bu görüntüyü sonraki katmanlarda işlemeye hazır hale getirir. Daha sonra mimarinin en önemli bileşeni evrimsel katmanlarda 3x3 filtreler ile doğrusal olmayan özelliklerin öğrenilmesine katkı sağlayan ReLU aktivasyon fonksiyonu kullanılarak giriş görüntüsünden özellik çıkararak modelin nesneleri tanımasını sağlar. VGG-16 modelinde 13, VGG-19 modelinde ise 16 konvolüsyon katmanı bulunmaktadır. Bu konvolüsyon katmanları ardışık olarak uygulanır ve her bir katman giriş verisinin daha karmaşık özelliklerini öğrenmektedir. Bir sonraki katman olan maksimum havuzlama katmanında ise 2x2 boyutunda havuzlama penceresi kullanarak özellik haritalarının boyutunu küçültülür ve bilgi yoğunluğunu artırılır. Mimarinin son katmanında yer alan tam bağlantılı katmanlarında ise konvolüsyon ve maksimum havuzlama katmanlarından gelen özellik haritaları alınarak bu bilgiler sınıflandırma için işlenir. VGG-16 ve VGG-19'da olduğu gibi genellikle her bir nöronun önceki katmandaki tüm nöronlarla bağlantılı olduğu üç tam bağlı katman bulunmaktadır. İlk iki tam bağlantılı katman her birinde bulunan 4096 nörondan oluşur ve karmaşık özelliklerin öğrenilmesini sağlar. Üçüncü tam bağlantılı katmanda ise sınıflandırma yapılacak sınıf sayısına göre nöron içermektedir (Zakaria ve Hassim, 2024).

VGG'nin derin ve düzenli ağ yapısı mimarinin görüntü sınıflandırma işlemlerinde tercih edilmesine olanak sağlamaktadır. Mimaride, sabit boyutlu 3x3 konvolüsyon filtreleri ve 2x2 maksimum havuzlama katmanları kullanılarak, modelin daha karmaşık ve detaylı özellikleri öğrenilmektedir. Bu yapı sayesinde model her seviyede daha derin ve anlamlı bilgiler çıkararak görüntüdeki ince detaylar, farklı sınıflar arasındaki özellik farkları daha başarılı bir şekilde tanımlayabilmektedir. Basit ve düzenli mimarisi sayesinde VGG transfer öğrenme işlemlerinde de kolaylıkla kullanılabilir.

### 3.2.2.3. Artık Ağlar (ResNet)

Artık ağlar (Residual Networks, ResNet), yapay sinir ağlarında daha derin mimarilerle verimli öğrenme sağlamak amacıyla geliştirilmiş bir ESA mimarisidir. ResNet'i diğer ağlardan ayıran en büyük yeniliği, artık (residual) bağlantılar kullanarak katmanlar arasında bilgi akışını kolaylaştırmasıdır (He ve diğ., 2016). Böylece her bir katman yalnızca kendi işleminden geçen bilgiyi değil, aynı zamanda kendinden önceki katmanlardan gelen çıktıları da kullanabilmektedir. Bu bağlantılar, ağın daha derin yapılara sahip olmasına rağmen gradyan kaybı (vanishing gradient) sorununu önlemekte ve yüksek doğruluk sağlamaktadır. ResNet, özellikle derin öğrenme mimarilerinde sıkça görülen gradyan kaybı sorununu çözmesiyle 2015 yılında ImageNet yarışmasını kazanarak ün kazanmıştır (Russakovsky ve diğ., 2015). ResNet-18, ResNet-34, ResNet-50, ResNet-101 ve ResNet-152 gibi farklı katman derinliklerine sahip literatürde sıkça kullanılan versiyonları bulunmaktadır (Koonce, 2021). Adlarından da anlaşılacağı üzere ResNet varyasyonları sahip oldukları artık katman sayısına göre isimlendirilmektedir (Örn. ResNet-50: 50 artık katman). ResNet mimarisinin giriş katmanı, artık bloklar, geçiş katmanları ve sınıflandırma katmanı olmak üzere dört ana bileşeni bulunmaktadır (Şekil 3.9).



Şekil 3.9. ResNet Mimarisi(Ergene ve diğ., 2024)

ResNet'in giriş katmanı genellikle 7x7 boyutunda bir konvolüsyon filtresine sahip modele giren ham görüntüyü işleyen ilk katmanıdır. Ardından gelen maksimum havuzlama katmanı ile özellik haritalarının boyutunu küçültür ve yoğunlaştırır. Bu katmandan sonra gelen ve ResNet'in en karakteristik bileşeni olan artık bloklar ise giriş bilgisini işlemeyen çıktıya doğrudan aktaran bir yol (skip connection) ekleyerek çalışmaktadır. Artık bloklar basit (basic) blok ve darboğaz (bottleneck) blok olmak üzere iki ana yapı içermektedir. Basit blok daha az derinliğe sahip olan versiyonlarda bulunmakta olup 3x3 konvolüsyon katmanı içermektedir ve her bir konvolüsyon işleminden sonra yığın normalleştirme (batch normalization) ve ReLU aktivasyon fonksiyonu uygulanır. Darboğaz blok ise genellikle daha derin versiyonlarda kullanılmaktadır ve sırasıyla 1x1 konvolüsyon katmanı ile özellik sayısını azaltır, daha sonra 3x3 konvolüsyon katmanı ile asıl özellik çıkarım işlemi yapılır ve en son olarak


1x1 konvolüsyon katmanı ile özellik boyutu eski haline geri getirilir (Xu ve diğ., 2023). Bu yapı sayesinde daha az parametre ile daha derin yapılar kolaylıkla eğitilebilir hale gelmektedir. Bu katmanı takip eden bir sonraki katman olan geçiş katmanında (downsampling) ise görüntü boyutu kademeli olarak küçültülerek özellik haritaları daha yoğun hale getirilir. Bunun için 1x1 konvolüsyon veya maksimum havuzlama katmanları kullanılmaktadır. Bu katmanın iki ana amacı vardır; özellik haritalarının boyutunu küçülterek daha kompakt bir veri temsiline ulaşılması ve her geçiş aşamasında daha karmaşık özelliklerin öğrenilebilmesi için özellik haritalarının sayısı artırılmasıdır. Mimarinin son bölümü olan çıkış katmanında ise çıkarılan özelliklerin sınıflandırılması için sınıflandırma katmanı bulunmaktadır. Bu katmanda genellikle küresel ortalama havuzlama katmanı ile özellik haritalarının ortalaması alınarak her sınıf için bir çıkış değeri üretilir ve ardından tam bağlantılı bir katman ile softmax aktivasyon fonksiyonu kullanılarak sınıflandırma işlemi gerçekleştirilir (McNeely-White ve diğ., 2020).

ResNet'in derin öğrenme mimarileri arasında öne çıkartan özelliği, artık bağlantılar sayesinde gradyan kaybı sorununu önleyerek daha derin mimarilerde daha karmaşık veri yapıları üzerinde yüksek doğruluk oranlarına ulaşılmasını sağlamasıdır. Ayrıca, modelin her bir katmanda yalnızca artık bilgiyi öğrenmesi, daha az parametreyle daha iyi performans sergilemesine yardımcı olur. Darboğaz bloklar ise parametre verimliliğini artırarak modelin hesaplama maliyetini düşürmekte ve derin yapısını koruyarak daha hafif bir model ortaya koymaktadır. Tüm bu avantajları, ResNet'i görüntü sınıflandırma ve segmentasyon gibi birçok derin öğrenme görevinde güçlü bir araç haline getirmekte ve birçok derin öğrenme modellerinde de kullanılmasına olanak sağlamaktadır.

#### 3.2.2.4. EfficientNet

EfficientNet, derin öğrenme modellerinde daha yüksek verim ve doğruluk sağlamak için ölçeklendirme metodu ile geliştirilmiş ESA temelli bir mimaridir. EfficientNet, model derinliğini, genişliğini ve çözünürlüğünü, en önemli özelliği olan bileşik ölçeklendirme (compound scaling) ile dengeli bir şekilde ölçeklendirerek hem yüksek performans hem de düşük hesaplama maliyeti sunmayı amaçlamaktadır (Şekil 3.10) (Tan ve Le, 2019). Geleneksel yöntemlerde modelin yalnızca bir boyutunu ölçeklendirmek sınırlı performans sağlamaktadır ancak EfficientNet tüm boyutları

dengeli bir şekilde ölçeklendirerek modelin daha etkili olmasını sağlamaktadır. Örnek olarak derinlik ölçeklendirilmesi ile modeldeki katman sayısını artırarak daha derin bir yapı edilmesi, genişlik ölçeklendirilmesi ile her katmandaki nöron sayısını artırarak modelin her bir katmanda daha fazla özellik öğrenmesinin sağlanması, çözünürlük ölçeklendirilmesi ile giriş görüntüsünün çözünürlüğünü artırarak daha ince ayrıntıların yakalanması gösterilebilir. EfficientNet, bu üç boyutu aynı anda ölçeklendirerek modelin daha dengeli ve verimli olmasını sağlamaktadır. Bileşik ölçeklendirme faktörü (compound coefficient) adı verilen bir parametre ile modelin boyutları birlikte artırılır (Ergene ve diğ., 2024).



**Şekil 3.10.** EfficientNet Mimarisinde Model Ölçeklendirme; (a) Temel bir ağ yapısının örneği; (b)-(d) ağın yalnızca bir boyutunu artıran geleneksel ölçeklendirme yöntemleri: genişlik, derinlik veya çözünürlük ölçeklendirmesi. (e) ise sabit bir oranla tüm boyutları eşit olarak ölçeklendiren bileşik ölçeklendirme yöntemini göstermektedir (Ergene ve diğ., 2024)


Genel yapısı ile EfficientNet mimarisi temelde bir ESA mimarisi olup, MobileNetV2 ve ters kalan blokları (MBConv) gibi verimli bileşenleri temel almaktadır (Dong ve diğ., 2020). EfficientNet'in temel versiyonu olan EfficientNet-B0 modeli, bu mimarinin en küçük ve temel halidir. Daha büyük EfficientNet versiyonları (B1, B2, ..., B7) bileşik ölçeklendirme stratejisi ile bu temel modelin daha büyük ölçekli versiyonlarıdır. Mimaride giriş katmanından sonra en temel yapı taşı olan MBConv blokları parametre sayısını düşük tutarak daha hızlı ve verimli bir özellik çıkarma işlemi gerçekleştirir. Bu bloklarda genellikle girişten gelen özelliklerin azaltılması için 1x1 konvolüsyon, derinlik çarpan konvolüsyonu (depthwise convolution), genişletme ve daraltma katmanları, sıkıştırma ve uyarı (squeeze and excitation) blokları bulunur. Bu yapı sayesinde modelin farklı ölçeklerde özellikler öğrenmesi sağlanmaktadır. Daha

sonra son özellik haritalarını küresel ortalama havuzlama işlemi ile özellik haritasının ortalamasını alarak veriyi daha kompakt hale getirir ve tam bağlantılı katman sayısını azaltır ve çıkış katmanında ise sınıflandırma işlemi gerçekleştirilir (Koonce, 2021). EfficientNet, farklı ölçeklendirme stratejileri kullanılarak optimize edilmiş bir dizi derin öğrenme modelinden oluşmaktadır. Literatürde sıkça kullanılan versiyonları arasında EfficientNet-B0, EfficientNet-B1, EfficientNet-B2, EfficientNet-B3, EfficientNet-B4, EfficientNet-B5, EfficientNet-B6 ve EfficientNet-B7 bulunmaktadır. Bu versiyonlar, ölçeklendirme faktörlerine göre adlandırılmıştır. Örneğin, EfficientNet-B0 temel model olarak kabul edilirken, EfficientNet-B7 en büyük ve en karmaşık modeldir.

EfficientNet'in görüntü sınıflandırma ve nesne algılama işlemlerinde sıkça tercih edilmesinin ardında, bileşik ölçeklendirme stratejisiyle sağladığı birçok avantaj bulunmaktadır. EfficientNet'in ilk ve en önemli avantajı, bileşik ölçeklendirme yöntemi sayesinde modelin derinlik, genişlik ve çözünürlüğünü dengeli bir şekilde artırarak daha verimli bir öğrenme imkanı sunmasıdır. Ayrıca, MBConv blokları gibi verimli yapı taşları sayesinde, hesaplama maliyeti düşük tutulurken parametre sayısı optimize edilmekte ve bu sayede model daha kompakt hale gelmektedir. EfficientNet'in düşük hesaplama maliyeti ile yüksek doğruluk sunması, modelin sınırlı kaynaklara sahip cihazlarda bile etkili bir şekilde çalışmasına olanak tanımaktadır.

### 3.2.2.5. Siyam Ağları

Siyam Ağları (Siamese Networks), iki veri örneğinin benzerlik veya farklılık derecesini öğrenmek amacıyla kullanılan özel bir sinir ağı mimarisidir. İlk olarak imza doğrulama ve yüz tanıma gibi uygulamalarda kullanılan Siyam Ağları, iki farklı veri örneğini aynı ağırlıklara sahip iki alt ağ üzerinden geçirerek özellik çıkarımı yapar ve bu örneklerin benzer olup olmadığını öğrenir (Bromley ve diğ., 1993). Bu ağların en önemli özelliği, iki veri örneğini aynı şekilde işleyen ve ağırlıklarını paylaşan ikiz alt ağlar kullanmasıdır. Bu sayede, her iki veri örneği için aynı özellik çıkarımı süreci gerçekleşir ve model benzerlik analizini adil bir şekilde yapabilir (Koch ve diğ., 2015). Siyam ağlarının temel yapısında giriş katmanı, özellik çıkarım katmanları, karşılaştırma katmanı ve çıkış katmanı olmak üzere dört ana bileşen bulunmaktadır (Şekil 3.11).



Şekil 3.11. Siyam Ağları Mimarisi

Giriş katmanında, iki farklı sınıfa ait veriler ayrı ayrı işlenerek özellik çıkarımı yapılmak üzere birbirine eş ikiz alt ağlara yönlendirilir. Siyam ağlarının karakteristik özelliği olan bu alt ağlarda özellik çıkarımı için genellikle konvolüsyon, aktivasyon ve havuzlama katmanları içeren ESA mimarileri kullanılır. Bu ağlar arasında paylaşılan ağırlıklar, her iki veri örneğinin de aynı özellik çıkarımı sürecinden geçmesini sağlar ve böylece model, karşılaştırma yaparken adil bir değerlendirme yapabilmektedir. Bu ağlardan geçen her bir veri özellik haritalarından oluşan bir özellik vektörü ile temsil edilir. Bu vektörler, her iki veri örneği için de çıkarılan bilgilerin özeti olarak örnek verilebilir. Daha sonra bu vektörler karşılaştırma için bir sonraki katmana aktarılır. Karşılaştırma katmanında bu vektörlerin benzerlik derecesinin ölçülmesi için Öklid mesafesi kullanılmaktadır (Eşitlik 3.1) (Wang ve diğ., 2005).

$$d(A, B) = \sqrt{\sum_{i=1}^n (y_i - x_i)^2} \quad (3.1)$$


Burada A ve B özellik vektörlerinin üyesi  $A(x_1, y_1)$  ve  $B(x_2, y_2)$  noktaları  $n$  boyutlu bir uzayda düşünülebilir. Son olarak, karşılaştırma katmanında Öklid benzerliği ile elde edilen benzerlik veya farklılık ölçüsü çıkış katmanına iletilir. Çıkış katmanı, iki veri örneğinin benzer olup olmadığını belirlemek için bir skor veya sınıf etiketi üretir. Bu süreçte, genellikle ikili sınıflandırma (binary classification) yöntemi kullanılır ve örnekler benzerse 1 farklı ise 0 değeri üretir.

Siyam ağlarının sınıflandırma uygulamalarında sıkça tercih edilmesinin ardında iki veri örneğini aynı anda işleyebilen paylaşılmış ağırlık yapısının sağladığı avantajlar gösterilebilir. Öncelikle iki veri örneğinin işleyebilen ikiz ağ yapısına sahip olması sayesinde yetersiz ve dengesiz veri seti bulunan sınıflandırma uygulamalarında başarılı sonuçlar vermektedir. Ayrıca, paylaşılan ağırlıklar sayesinde hem veri örneklerinin

ortak özelliklerini etkili bir şekilde öğrenmekte hem de model parametreleri optimize edilerek hesaplama maliyeti düşürülmektedir.

### 3.2.2.6. Prototip Ağları

Prototip Ağları (Prototypical Networks), özellikle sınıflandırma için az veya dengesiz veri seti bulunan durumlarda sıkça kullanılan ve her sınıfın prototipini öğrenmeye dayalı bir sinir ağı modelidir. Az örnekle öğrenme (few-shot learning) problemlerini çözmek için geliştirilmiştir. Bu ağ yapısı, siyam ağlarında olduğu gibi alt ağlar içerirken aynı zamanda sınıflar arasındaki benzerlik ve farklılıkları öğrenmek için veri örneklerinin merkezini temsil eden prototip olarak adlandırılan temsilciler oluşturur. Öğrenme sürecinde her sınıf için tek bir prototip belirlenerek, modele az örnekle sınıflandırma yapabilme yeteneği kazandırılmaktadır (Snell ve diğ., 2017). Prototip ağlarının ana bileşenleri Şekil 3.12’de görüleceği üzere giriş katmanı, özellik çıkarım katmanları, prototip hesaplama, mesafe hesaplama ve çıkış katmanlarıdır.



Şekil 3.12. Prototip Ağı Mimarisi

Prototip Ağlarının giriş katmanı diğer mimarilerdeki sınıf setleri girişlerinden farklı olarak destek kümesi ve sorgu kümesindeki veri örneklerini alır. Destek kümesi sınıfların temsil edilmesi için kullanılan örneklerden oluşurken, sorgu kümesi ise modelin sınıflandırma yapmaya çalışacağı örnekleri içermektedir. Destek kümesinde her sınıfa ait birkaç örnek bulunur ve bu örnekler sınıfların ortalama temsilini oluşturmak amacıyla kullanılır. Özellik çıkarımı katmanlarında ise Siyam ağlarında olduğu gibi bir ESA mimarisi ile özellik çıkarımı işlemi gerçekleştirilerek destek ve sorgu kümesindeki her bir veri örneği anlamlı bir özellik vektörü ile temsil edilir.

Destek kümesindeki her bir sınıfın özellik vektörleri elde edildikten sonra, ortalama özellik vektörleri hesaplanır. Bu ortalama vektör, sınıfın prototipi olarak adlandırılır ve o sınıfın genel temsili olarak kabul edilir. Prototipler, sınıfa ait tüm özellik vektörlerinin ortalamasıdır. Her sınıf için tek bir prototip vektörü oluşturulur ve bu prototip vektörleri, sınıflar arasındaki benzerliklerin değerlendirilmesinde kullanılır. Her bir sınıfın prototipi oluşturulduktan sonra sorgu kümesindeki her bir örnek ile bu prototipler arasındaki mesafe Siyam ağlarında olduğu gibi Öklid benzerliği kullanılarak ölçülür (Triantafillou ve diğ., 2019). Mesafe hesaplama işlemi sonucunda, sorgu örneği hangi sınıfın prototipine daha yakınsa, o sınıfa atanır ve çıkış katmanında örneğin hangi sınıfa ait olduğu belirlenir.

Prototip Ağlarının sınıflandırma işlemlerinde özellikle dengesiz veri seti bulunduğu durumlarda öne çıkmasının sebebi, her sınıf için ortalama bir temsil sağlayarak az veriyle yüksek doğruluk sunma yeteneğidir. Prototip Ağlarının avantajı, her sınıfın özelliklerini bir prototip ile temsil ederek, az örnekle bile sınıflandırma yapabilmesidir. Bu sayede, çok az veri bulunan veya yeni sınıflar için eğitim verisi eksik olan durumlarda bile etkili sonuçlar elde edilebilmektedir. Ayrıca, her sınıf için prototip oluşturarak sınıflar arası benzerlik ve farklılıkları net bir şekilde tanımlayabilmekte, bu sayede sınıflandırma görevini daha yüksek doğrulukla gerçekleştirmektedir.

### 3.2.2.7. Kolmogorov-Arnold Ağı

Kolmogorov-Arnold Ağı (KAN), Kolmogorov-Arnold temsili teoreminden esinlenerek geliştirilmiş bir sinir ağı mimarisidir (Kůrková, 1992). Bu teorem, karmaşık, çok değişkenli sürekli fonksiyonları daha basit alt fonksiyonlar kullanarak modellemek amacıyla formüle edilmiştir. Ayrıca, problemlerin boyutluluğunu azaltmada ve hesaplama karmaşıklığını en aza indirmede etkilidir.

Teorem iki adımdan oluşmaktadır. İlk adım 1957 yılında Andrey Kolmogorov tarafından geliştirilmiş, ikinci adım ise 1963 yılında Vladimir Arnold tarafından genişletilmiş ve tamamlanmıştır (Kůrková, 1992).

Kolmogorov teoreminde, sınırlı bir tanım kümesindeki herhangi çok değişkenli aşağıdaki gibi bir fonksiyonun (Eşitlik 3.2):

$$f(x_1, x_2, \dots, x_n) \quad (3.2)$$


Tek değişkenli fonksiyonların bir üst üste bindirilmesi (süperpozisyonu) olarak aşağıdaki şekilde ifade edilebileceği kanıtlanmıştır (Eşitlik 3.3):

$$f(x_1, x_2, \dots, x_n) = \sum_{q=1}^{2n+1} \phi_q \left( \sum_{p=1}^n \psi_{pq}(x_p) \right) \quad (3.3)$$

$\phi_q$  ve  $\psi_{pq}$  sürekli fonksiyonlardır. Bu çok değişkenli fonksiyonlar, her bir değişken üzerinde çalışan fonksiyonlar ve bu fonksiyonların çıktıları birleştirilerek tanımlanabilir. Arnold, bu teoremi genişleterek, her sürekli  $n$  değişkenli fonksiyonun  $2n+1$  tekdüze fonksiyonun süperpozisyonu olarak temsil edilebileceğini göstermiştir. Arnold'un bu katkısı, teoremin uygulanabilirliğini artırmıştır (Arnold, 2009).

Kolmogorov-Arnold Ağı, bu teorem temel alınarak tasarlanmıştır. Çok değişkenli bir fonksiyon  $f(x)$ , daha basit bileşenlere bölünerek yaklaşık olarak hesaplanır. Bu sayede fonksiyon, çeşitli uygulamalar için hesaplama açısından verimli ve esnek hale gelir. Yapı, ayrıştırma (decomposition) ve süperpozisyon (superposition) olmak üzere iki aşamadan oluşmaktadır. Ayrıştırma aşamasında, giriş olarak verilen çok değişkenli fonksiyon  $f(x_1, x_2, \dots, x_n)$ , birden fazla tek değişkenli alt fonksiyona ayrılır.

Özellikle, her bir giriş  $x_p$  için bir dizi fonksiyon  $\psi_{pq}(x_p)$  hesaplanır. Bu sürekli fonksiyonlar, her bir bireysel giriş değişkeni için (tez çalışmada termal görüntü) belirli özellikleri çıkarmak amacıyla geliştirilmiştir. Bu tür fonksiyonların sayısı  $2n + 1$ 'dir ve orijinal çok değişkenli fonksiyonun davranışını yeterli bir ayrıntı düzeyinde yakalamayı garanti eder. Süperpozisyon aşamasında, tek değişkenli fonksiyonlar hesaplandıktan sonra bir toplama işlemiyle birleştirilir. Her toplama işlemini, başka bir tek değişkenli fonksiyonlar seti olan  $\phi_q$ 'nin uygulanması takip eder. Bu fonksiyonlar,  $\psi_{pq}$  fonksiyonlarının çıktısını birleştirerek tekil temsillere dönüştüren birer bütünleştirici görevi görür.  $\phi_q$  fonksiyonları da sürekli olup, ele alınan probleme göre özelleştirilebilir. Bu aşama, daha basit ve tekdüze alt fonksiyonların süperpozisyonu olarak orijinal çok değişkenli fonksiyonu etkili bir şekilde yeniden yapılandırır (Liu ve diğ., 2024). Kolmogorov-Arnold Ağı mimarisi Şekil 3.13'te verilmiştir.



Şekil 3.13. Kolmogorov-Arnold Ağı Mimarisi (Jamali ve diğ., 2024)

Şekil 3.13'te alt kısımda yer alan düğümler,  $f(x_1, x_2, \dots, x_n)$  fonksiyonundaki girdileri ifade eden  $x_1, x_2$  gibi değerlerdir. Alt blok incelendiğinde, fonksiyonlar  $\phi_{1,1}, \phi_{2,1}$  gibi 1-boyutlu fonksiyonlardır. Tüm bloklar  $\psi_{pq}$  katmanlarıdır. Bu şekilde  $\psi_1$ , 2x4 boyutunda bir katman olarak tanımlanmıştır ve  $\psi_2$  ise 4x1 boyutunda bir katmanı temsil etmektedir. Kenarlar üzerindeki öğrenilebilir aktivasyon fonksiyonları, düğümlerdeki toplama işlemleri aracılığıyla ağın karmaşık fonksiyonları etkili bir şekilde modellemesine olanak tanır. İki aşamalı bu süreç sayesinde Kolmogorov-Arnold Ağı, çok değişkenli bir giriş uzayıyla doğrudan çalışmaktan kaçınarak modelleme için gereken karmaşıklık ve parametre sayısını azaltır. Bu yapı, özellikle büyük boyutlu veri senaryolarında, orijinal fonksiyonun temsilini basitleştirirken hassasiyet ve yorumlanabilirlik sağlaması açısından oldukça avantajlıdır.

Kolmogorov-Arnold Ağları, karmaşık fonksiyonları daha az parametreyle modelleme yetenekleri sayesinde hesaplama verimliliği sağlamalarının yanı sıra, boyutluluk azaltma ve yorumlanabilirlik açısından da önemli avantajlar sunmaktadır. İlk olarak, geleneksel sinir ağlarından daha az parametre gerektirmesi sayesinde, hesaplama verimliliği sağlarken doğruluğu korur. Bu özelliği, ağı sınırlı kaynaklara sahip uygulamalar için uygun hale getirmektedir. Ayrıca, Kolmogorov-Arnold Ağı'nın sadeleştirilmiş yapısı, küçük veri setleriyle çalışırken aşırı öğrenme riskini azaltır. Geniş kapsamlı verileri daha yalın ve sistemli fonksiyonlara ayrıştırarak hem hesaplama

süreçlerini büyük ölçüde kolaylaştırır hem de işlem hızını artırır; böylece boyut indirgeme konusunda etkili bir araç haline gelir.

Kolmogorov-Arnold Ağı, regresyon, sınıflandırma ve özellik çıkarma gibi farklı görevlerde yüksek uyarlanabilirlik sağlayarak çeşitli alanlarda kullanılabilmektedir. Bir diğer avantajı ise yorumlanabilirliğidir. Bu ağın yapısı, girdilerin çıktılar üzerindeki etkilerinin daha iyi anlaşılmasını sağlar. Özellikle tıp gibi yorumlanabilirliğin kritik öneme sahip olduğu bilimsel alanlarda, bu özellik büyük değer taşımaktadır (Hou ve Zhang, 2024).

Kolmogorov-Arnold Ağının sahip olduğu avantajlarına rağmen bazı sınırlamaları da bulunmaktadır. Eğitim süreci, özellikle probleme özgü gereksinimlerin karmaşık olduğu durumlarda zorlu hale gelebilmektedir. Bu zorluk  $\phi_q$  ve  $\psi_{pq}$  fonksiyonlarının, çalışılacak veri seti ve hedef göreve uygun şekilde tasarlanmasını ve optimize edilmesini zorunlu kılar. Veri setinin çok değişkenli, karmaşık ya da yüksek doğruluk gerektiren bir problem yapısına sahip olduğu durumlarda, fonksiyonların özelleştirilmesi matematiksel modelleme, veri analizi ve uygulama alanına dair uzmanlık gerektirmektedir. Daha basit veri setleri veya standart problemler için süreç daha az karmaşık olmakla birlikte, spesifik problemlerde uzman müdahalesi kaçınılmazdır. Geleneksel aktivasyon fonksiyonlarını kullanmadığı için geleneksel sinir ağlarından farklıdır ve bu durum uygulamayı daha zor hale getirebilmektedir. Kolmogorov-Arnold Ağı, nispeten yeni bir yöntem olduğu için, yaygın makine öğrenimi platformlarına henüz tam anlamıyla entegre edilmemiştir; bu durum da erişilebilir kaynakların kısıtlı olmasına yol açmaktadır. Geleneksel yapay zeka yöntemleri gibi küçük ve orta ölçekli veri setlerinde verimli olsa da çok büyük veri setleri üzerinde ölçeklendirme yaparken zorluklar ortaya çıkabilmekte ve ek optimizasyon teknikleri gerektirebilmektedir. Son olarak, Kolmogorov-Arnold Ağının uygulanması için standart bir yöntem bulunmamaktadır. Bu durum, yapının ve tasarımın araştırmacıya ve ele alınan probleme bağlı olarak büyük ölçüde değişiklik gösterebileceği anlamına gelmektedir.

### 3.3. Performans Değerlendirme Ölçütleri

Yapılan sınıflandırma ve segmentasyon çalışmalarının başarısını ölçmek için kayıp (Loss), doğruluk (Accuracy), kesinlik (Precision), duyarlılık (Recall) ve F1 Skoru

metrikleri kullanılmıştır. Kayıp, bir makine öğrenimi modelinin tahminleri ile gerçek değerler arasındaki farkı belirten bir ölçüttür. Genellikle bir hedef fonksiyonun minimize edilmesiyle elde edilmektedir. Kayıp fonksiyonları, modelin performansını değerlendirme ve optimize etme sürecinde önemli bir rol oynamaktadır. İkili Çapraz Entropi Kaybı (Binary Cross Entropy Loss), iki sınıfın sınıflandırılmasında kullanılan bir yöntemdir. Bu fonksiyon, modelin tahminlerinin gerçek etiketlerle uyum düzeyini değerlendirir ve iki sınıf arasındaki olasılık dağılımlarını karşılaştırarak modelin başarısını ortaya koymaktadır. İki sınıf arasındaki olasılık dağılımlarını karşılaştırılarak modelin performansını ölçülmektedir. İkili çapraz entropi kaybı, Eşitlik 3.4'teki gibi ifade edilmektedir (Shannon, 1948).

$$L = - [y * \log(y_{pr}) + (1 - y) * \log(1 - y_{pr})] \quad (3.4)$$

Burada,  $y$  gerçek etiket (0 veya 1) ve  $y_{pr}$  model tarafından tahmin edilen olasılık değeridir. Bu fonksiyondaki temel fikir, doğru sınıflandırmalar ve yanlış sınıflandırmaların farklı oranlarda kayıplara yol açabilmesidir. Doğru tahminler için herhangi bir kayıp oluşmaz, çünkü  $\log(1) = 0$ 'dır. Ancak yanlış tahminlerde kayıp artar ve daha büyük bir değer elde edilir. Fonksiyon, gerçek etiket 0 olduğunda  $(1-y)$  terimini, gerçek etiket 1 olduğunda ise  $y$  terimini kullanır.

Karşıt kayıp (Contrastive Loss), özellikle metrik öğrenme veya Siyam ağları gibi görevlerde kullanılan bir kayıp fonksiyonudur. Bu tür görevlerde amaç, giriş çiftleri arasındaki benzerlik fonksiyonunu öğrenmektir. Bu fonksiyon, modelin benzer çiftler arasındaki mesafeyi minimize ederek ve farklı çiftler arasındaki mesafeyi maksimize ederek benzer ve farklı çiftleri ayırt etmesine yardımcı olur. Karşıt kayıp, özellikle modelin iki giriş arasındaki benzerliği veya farkı ölçmesi gereken durumlarda oldukça faydalı olmaktadır (Eşitlik 3.5) (Bromley ve diğ., 1993).

$$L = 1/2 (y * D^2 + (1-y) * \max [(0, m-D)]^2) \quad (3.5)$$

Burada,  $y$ , çiftin benzer (1) veya farklı (0) olduğunu belirten ikili etiketi ifade etmektedir.  $D$ , iki özellik vektörü arasındaki Öklid mesafesini temsil eder.  $m$ , farklı çiftler arasındaki minimum mesafeyi tanımlayan ve hiper parametre olarak kullanılan bir sınır değeridir.

Kesinlik, sınıflandırma modelinin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten doğru olduğunu gösteren bir metriktir. Yani, doğru pozitiflerin toplam pozitif tahminlere oranıdır. Kesinlik, Eşitlik 3.6'daki formül ile hesaplanmaktadır (Olson ve Delen, 2008).

$$\text{Kesinlik} = \text{DP} / (\text{DP} + \text{YP}) \quad (3.6)$$

Burada, DP (Doğru Pozitif) doğru olarak pozitif sınıflandırılmış örneklerin sayısını, YP (Yanlış Pozitif) ise yanlış bir şekilde pozitif sınıflandırılmış örneklerin sayısını ifade etmektedir. Çalışmamızda, DP, doğru bir şekilde sınıflandırılmış sağlıklı görüntülerin sayısını, YP ise yanlış bir şekilde sağlıklı olarak sınıflandırılmış görüntülerin sayısını temsil etmektedir. DN (Doğru Negatif) doğru bir şekilde sınıflandırılmış yaralı görüntülerin sayısını ifade etmektedir. YN (Yanlış Negatif) ise bir sonraki formülde verilen, yanlış bir şekilde sınıflandırılmış yaralı görüntülerin sayısını ifade etmektedir.

Duyarlılık, doğru pozitiflerin tespit edilme oranını ifade etmektedir. Duyarlılık, Eşitlik 3.7'deki formül ile hesaplanmaktadır (Olson ve Delen, 2008).

$$\text{Duyarlılık} = \text{DP} / (\text{DP} + \text{YN}) \quad (3.7)$$

F1 Skoru, bir sınıflandırma modelinin kesinlik ve duyarlılık metriklerinin bir kombinasyonudur. F1 Skoru, modelin yanlış pozitifleri (yanlış şekilde pozitif olarak sınıflandırılan örnekler) ve yanlış negatifleri (yanlış şekilde negatif olarak sınıflandırılan örnekler) dikkate alır. F1 Skoru, Eşitlik 3.8'deki formül ile hesaplanmaktadır (Olson ve Delen, 2008).

$$\text{F1} = 2 * ((\text{Kesinlik} * \text{Duyarlılık}) / (\text{Kesinlik} + \text{Duyarlılık})) \quad (3.8)$$

Doğruluk, doğru sınıflandırmaların oranını ifade etmektedir ve Eşitlik 3.9'daki formül ile hesaplanmaktadır (Olson ve Delen, 2008).

$$\text{Doğruluk} = (\text{DP} + \text{DN}) / (\text{DP} + \text{YP} + \text{YN} + \text{DN}) \quad (3.9)$$

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu tez kapsamında futbolcu termal görüntülerinden yapay zeka ile hamstring yaralanmalarının tespiti üzerine çeşitli çalışmalar gerçekleştirilmiştir.

İlk olarak futbolcularda kas yaralanmalarının termografik görüntülerde hangi karakteristik özellikleri sergilediğinin incelenmesi için doğrulama çalışmaları yürütülmüştür. Daha sonra sporcuların alt ekstremité görüntülerinden kas bölgelerinin segmentasyonu yapılmıştır. Son olarak da segmente edilen kas görüntülerinden hamstring yaralanmasının tespiti için farklı yapay zeka yaklaşımları geliştirilmiştir.

##### 4.1. Termografinin Sporcu Yaralanmalarında Kullanımı

Sporcularda meydana gelen kas yaralanmaları ve yorgunluk, ilgili kas bölgesindeki hasar nedeniyle inflamasyona yol açmaktadır ve bu durum, her iki bacağın eşdeğer kas bölgeleri arasında sıcaklık farkı olarak kendini göstermektedir. Bu sıcaklık farklılıkları termal görüntüleme yöntemiyle gözlemlenebilmektedir. Bu bölümde yaralanmalardan kaynaklı meydana gelen sıcaklık değişikliklerinin incelendiği tıbbi doğrulama çalışmalarına değinilmiştir.


##### 4.1.1. Futbolda Menisküs Yaralanmalarının Belirlenmesinde Termografinin Kullanımı

Menisküs yaralanmalarının sıklığı, Amerika Birleşik Devletleri'ndeki genel popülasyonda yılda her 1000 kişi için 0,61 ila 0,70 arasında değişirken, genç ve fiziksel olarak aktif bireylerde bu oran 1000 kişi başına 8,27'ye kadar çıkabilmektedir (Gee ve diğ., 2020). Medial menisküs yaralanmaları, lateral menisküs yaralanmalarına kıyasla daha sık görülmekte olup, futbolcularda medial menisküs yaralanma oranı %74, lateral menisküs oranı ise %26 olarak bildirilmiştir (Baker ve diğ., 1985). Ancak, sağ ve sol taraf arasında anlamlı bir fark tespit edilmemiştir. Küçük periferik yırtıkların iyileşme potansiyeli olduğundan, cerrahi dışı bir tedavi süreci genellikle uygundur. Bununla birlikte, 4-6 haftadan uzun süren semptomlar veya diz kilitlemesi gibi ciddi belirtiler ortaya çıktığında, yaralanmanın MRG taramaları ve artroskopi ile değerlendirilmesi önerilmektedir (Tucker, 1997). Son yıllarda termografi üzerine yapılan araştırmalar, bu

yöntemin spor yaralanmalarının erken tespiti için kullanılabileceğini göstermektedir. Termografi, ekstremiteler arasındaki sıcaklık asimetrisini değerlendirerek, sporcu sağlığıyla ilgilenen uzmanlara kullanımı kolay ve invaziv olmayan bir değerlendirme yöntemi sunmaktadır (Hildebrandt ve diğ., 2010; Côté ve diğ., 2019; Gomez-Carmona ve diğ., 2020).

#### 4.1.1.1. Vaka Sunumu ve Sonuçlar


20 yaşında, 191 cm boyunda ve 70 kg ağırlığında Türkiye Süper Ligi'nde kaleci olarak oynayan sporcu, antrenman sırasında sol dizinin medial bölgesinde ağrı hissettiğini ifade etmiştir. Sağ tarafta benzer bir bulguya rastlanmamıştır. Yaralanmanın olduğu gün dinlenik halde yapılan termografik görüntülemeye, sol diz medial bölgesinde belirgin bir ısı artışı tespit edilmiştir. Bunun üzerine, bir gün sonra sporcunun MRG'si yapılmış ve sonuç olarak menisküs yaralanması teşhisi konulmuştur. Yaralanmanın olduğu gün yapılan termografik görüntülemeye sağ diz bölgesi ile sol diz bölgesi arasında, sağ tarafın daha yüksek olduğu 0,68°C'lik bir ortalama sıcaklık farkı tespit edilmiştir. Bölgelerin minimum sıcaklık değerlerinde belirgin bir fark gözlenmezken, maksimum sıcaklık farkının ise sol tarafta daha yüksek olduğu 1,41°C olarak ölçülmüştür (Şekil 4.1). Bu durum, sporcunun sol diz bölgesinde bir yaralanma olabileceğine işaret etmektedir. Bu nedenle, özellikle ağrı hissedilen bölgedeki sıcaklık farkını değerlendirmek amacıyla rehabilitasyon süresi boyunca termografik görüntüleme yapılmasına karar verilmiştir.



Şekil 4.1. Yaralanmanın gerçekleştiği gün futbolcunun termografik görüntüsü

(S1: sağ diz bölgesi, S2: sol diz)


Diz bölgesindeki yaralanmadan dolayı yapılan özel çekim pozisyonunda, sol tarafın ağrı hissedilen bölgesine karşılık gelen alan ile sağ tarafın aynı bölgesi belirlenmiş ve sıcaklık analizi gerçekleştirilmiştir. Analiz sonuçlarına göre, sol taraf ağrı olan bölgenin, sağ tarafın aynı bölgesine göre  $0,18^{\circ}\text{C}$  daha yüksek sıcaklığa sahip olduğu belirlenmiştir. Bölgelerin minimum sıcaklık değerlerinde ise  $0,04^{\circ}\text{C}$  fark tespit edilmiş ve bu durumda sağ tarafın daha yüksek olduğu görülmüştür. Aynı alanlar üzerinde yapılan analizlerde, maksimum sıcaklık farkının  $1,30^{\circ}\text{C}$  ile sol tarafta daha yüksek olduğu saptanmıştır (Şekil 4.2). Bu bulgular, sporcunun ağrı şikayetlerinin termal görüntüleme sonuçlarıyla uyumlu olduğunu ortaya koymaktadır.



**Şekil 4.2.** Yaralanmanın gerçekleştiği gün futbolcunun özel çekim pozisyonu ile yapılan termografik görüntüsü **(a)** sağ diz bölgesi, **(b)** sol diz bölgesi

Analiz edilen veriler doğrultusunda,  $0,4^{\circ}\text{C}$  ve altındaki sıcaklık farklılıkları normal,  $0,5^{\circ}\text{C}$  ile  $0,7^{\circ}\text{C}$  arasındaki sıcaklık farkları izlenmesi gereken bölge ve  $0,8^{\circ}\text{C}$  ile  $1,5^{\circ}\text{C}$  arasındaki farklar ise ilgili bölgede olası bir yaralanmanın göstergesi olarak sınıflandırılmıştır (Quesada, 2017).

Sporcunun bir gün sonra MR görüntüsü alınmıştır. Sporcunun 1. derece medial menisküs yaralanması olduğu raporlanmıştır (Şekil 4.3).



Şekil 4.3. Futbolcunun yaralanmadan bir gün sonra çekilen diz MR görüntüsü


#### 4.1.1.2. Tartışma

Bu çalışmada, antrenmanlarına devam eden ve diz ağrısı şikayeti bulunan bir sporcunun yaralanması, termografik yöntem kullanılarak tespit edilmiş ve tedavi sürecine başlanmıştır. Yaralanmanın ilk olarak termografi ile tespit edilmesi ve ardından MRG ile aynı tanının doğrulanması, bu çalışmanın literatüre önemli bir katkı sağladığını göstermektedir. MRG gibi detaylı anatomik görüntüleme yöntemlerine ek olarak, termografi, sporcu yaralanmalarında hızlı ve ekonomik bir ön tarama aracı olarak öne çıkmaktadır. Özellikle geniş sporcu gruplarının hızlı bir şekilde değerlendirilmesi ve kritik durumların önceliklendirilmesi açısından önemli bir tamamlayıcı yöntemdir. Termografi, kas-iskelet sistemi yaralanmalarında sıcaklık değişikliklerini ve asimetrisi tespit ederek, detaylı inceleme gerektiren durumların belirlenmesinde etkili bir rol oynamaktadır.

Sporcuların menisküs yaralanmalarına karşı düzenli taramalardan geçmesi gerektiği ve erken müdahale programları ile bu tür yaralanmaların önlenebileceği göz önüne alındığında, termografi yöntemi antrenman öncesi-sonrasında veya yaralanma şüphesi bulunan durumlarda hızlı bir tarama aracı olarak kullanılabilir. Bu yöntem sayesinde, erken teşhis ile sporcuların antrenmanlardan uzun süre uzak kalmadan tanı, tedavi ve takip süreçlerinin yönetilmesi mümkün olmaktadır. Ayrıca, menisküs yaralanmalarının daha etkin bir şekilde belirlenmesi için, sporcuların anterior ve posterior pozisyonlarının yanı sıra lateral pozisyonda da görüntü alınması önerilmektedir. Böylece, termografinin menisküs yaralanmalarının ilerlemesini önlemede etkili bir araç olarak kullanılabileceği değerlendirilmektedir. Ayrıca, diğer görüntüleme yöntemlerini destekleyen ön değerlendirme ve takip süreçlerinde önemli bir rol oynayabileceği öngörülmektedir (Bayrak ve diğ., 2021b).

#### 4.1.2. Profesyonel Bir Futbolcuda Rektus Femoris Proksimal Yırtığı Sonrası Kızılötesi Termografi ile Spora Dönüş Sürecinin Değerlendirilmesi

Rektus femoris (RF), musculus quadriceps femoris kasının dört bölümünden biridir. Caput rektum, spina iliaca anterior inferiordan başlarken, caput reflex ise acetabulumun üzerindeki os iliumdan başlar. İki baş, kalça ekleminin ön kısmında birleşir. Çift taraflı bir yapı (bipennate) şeklinde olan bu kas, patellada ortak bir tendon ile sonlanır (Snell, 2000) (Şekil 4.4).



Şekil 4.4. Rektus femoris kası anatomisi (Sobotta, 2005)

RF kası, diğer quadriceps kaslarından, daha fazla tip II fibril içermesi ve iki eklemden geçmesi nedeniyle ayrılmaktadır (Hasselman ve diğ., 1995). Futbolcularda yaygın olarak görülen RF yaralanmalarında, kronik yaralanmalar genellikle origo bölgesine daha yakinken, akut yaralanmalar daha çok alt bölgelerde meydana gelmektedir (Hawkins ve diğ., 2001; Miller ve diğ., 2012). RF yaralanmaları genellikle kalça fleksörleri ve diz ekstansörlerinin eksantrik yüklenmesi sonucu meydana gelmektedir (Mendiguchia ve diğ., 2013; Netter ve Hansen, 2018). Diz ekleminde ani ve güçlü bir ekstansiyon sırasında yırtılma oluşabilir. Kasın üst kısmı yukarı doğru çekilir ve yırtık bölgesinde bir boşluk oluşur. RF kas yırtılması sıklıkla gözden


kaçırıldığı için takip edilmesi zor bir yaralanma türüdür ve geleneksel tedavi süresi 6-12 hafta arasında sürmektedir (Snell, 2000; Gamradt ve diğ., 2009). Sporcular için yaralanma sonrası rehabilitasyon sürecinin ne zaman sonlandırılacağına, sahaya dönüş ve müsabakalara katılmaya karar verilmesi büyük önem taşımaktadır. Yanlış rehabilitasyon takibi ve sahaya dönüş kararı nedeniyle yaralanmanın tekrarlaması ise kaçınılmaz hale gelebilir (Esser ve diğ., 2015). Bu nedenle yaralanma sonrası rehabilitasyon takibi önem taşımaktadır. RF yaralanmalarının takibi USG ve MRG ile yapılmasına karşın, MRG yaralanmanın tanısının koyulmasında altın standart olarak öne çıkmaktadır. Ancak MRG'nin kullanımı ve maliyeti göz önüne alındığında rehabilitasyon takibi için her zaman ulaşılabilir bir araç olmamaktadır. Bunun yanında termografi maliyeti ve kolay kullanımı sayesinde rehabilitasyon takibi için uygun bir araç olarak öne çıkmaktadır. Bu çalışmada ise RF proksimal yırtığı olan profesyonel bir futbolcuda termografi ile yaralanma ve rehabilitasyon takibi gerçekleştirilmiştir.

#### 4.1.2.1 Vaka Sunumu

22 yaşında (172 cm, 72 kg) bir forvet oyuncusu, Türkiye Süper Ligi maçında uyluğun ön kısmında hissettiği şiddetli ağrı nedeniyle maçı tamamlayamamıştır. Maç sırasında sağ ayağıyla şut çekmeye çalışırken, sol ayağı çime takılmış ve sol quadriceps kası aşırı gerilmiştir. Sonrasında, üst uyluk bölgesinde ağrı hisseden sporcu, maça devam edememiş ve oyundan çıkmak zorunda kalmıştır. Maç sonrası yapılan termal incelemede, oyuncunun sol RF proksimalinde ağrı ve sağ-sol RF kasları arasında sıcaklık farkı tespit edilmiştir. Oyuncu, aktif kalça eklemi fleksiyona getirirken yanma hissi ve kalça ekleminde hareket kısıtlılığı yaşadığını belirtmiştir. 28 gün sonra yapılan USG sonucunda ise 2.5x1.2 mm çapında bir hematoma alanı gözlemlenmiştir. Sol uyluğun proksimal kısmında kas-tendon sürekliliğinin kaybı ile 3. derece kas zorlanması teşhisi konulmuştur, yine aynı tarihte yapılan MRG incelemesinde 3. derece rektus femoris yaralanması rapor edilmiştir. 3. derece RF proksimal tendon yırtığı tanısının ardından sporcu izleme programına alınmıştır. Kademeli rehabilitasyon programını takiben saha çalışmalarına katılan sporcu, ilk müsabakasına 103 gün sonra çıkmıştır. Sporcunun rehabilitasyon sürecinin takibi, tedavinin sonlandırılması, sahaya dönüşü ve müsabakalara katılımı termografik inceleme ile belirlenmiştir.

#### 4.1.2.2 Araştırma Sonuçları ve Tartışma


Şekil 4.5(a)'da yer alan görüntü, sporcunun yaralanmadan önceki rutin gözlemleri sırasında alınmıştır. Quadriceps kasının rektus kısmında sağ ve sol taraflar arasında ortalama  $0,34^{\circ}\text{C}$  fark olduğu görülmektedir. Yaralanan tarafın sıcaklık değerinin daha yüksek olduğu gözlemlenmiştir (bu fark, yaralanma öncesi riskin bir göstergesi olarak yorumlanabilir). Şekil 4.5(b), yaralanmadan 24 saat sonra alınan termal görüntüyü göstermektedir. Sağlıklı tarafın sıcaklık değeri, yaralı taraftan daha yüksek olmasına rağmen, arada  $0,7^{\circ}\text{C}$ 'lik bir sıcaklık farkı bulunmaktadır. Yaralanma bölgesi olan RF alanı yeşil olarak görülmektedir. Tam yırtılmaya uğramış bir kas, kasılma üretmemektedir. Bu durum, tam yırtılma nedeniyle kasın ağırlık transfer edememesinden kaynaklandığını düşündürmektedir. Sporcu dinlendirilmiş, fiziksel antrenmanları kısıtlanmış ve tedavi sürecine başlanmıştır.



**Şekil 4.5. (a)** Yaralanma öncesi termal görüntü. Yaralanma riski taşıyan bölgeler. (S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi) **(b)** Yaralanma sonrası termal görüntü. (S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi).


Şekil 4.6'te görüldüğü üzere, yaralanmadan 40 gün sonra rehabilitasyon antrenman programına katılan sporcunun ortalama sıcaklık farkının azaldığı ve minimum sıcaklık farkının  $5,52^{\circ}\text{C}$  olduğu gözlemlenmiştir. Yaralanma bölgesi olan RF kas alanındaki düşük kan dolaşımını gösteren yeşil alanın küçüldüğü görülmektedir. Bu bilgiler ışığında, rehabilitasyon programının başarılı olduğu ve sporcunun durumunun iyileştiği tespit edilmiştir. Ancak, tam saha çalışmaları için gerekli kas aktivitesine

henüz ulaşılmadığı görüldüğünden, rehabilitasyon antrenmanlarına devam edilmesine karar verilmiştir.




**Şekil 4.6.** Oyuncunun yaralanmadan 40 gün sonraki görüntüsü  
(S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi)

Şekil 4.7 incelendiğinde, yaralanmadan 50 gün sonra, rehabilitasyon programına 48 gün boyunca devam eden sporcunun termal görüntüsünde ortalama sıcaklık farkının  $0,59^{\circ}\text{C}$ , minimum sıcaklık farkının ise  $0,25^{\circ}\text{C}$  olduğu belirlenmiştir. 6. haftanın sonunda yapılan değerlendirmede, termal görüntüde simetrik bulgular elde edilmiştir. Ayrıca, sporcunun fiziksel muayenesinde de iyileşme tespit edilmiştir. Bu bulgular doğrultusunda sporcunun saha çalışmalarına başlamasına karar verilmiştir. Ancak, takımla yapılan şut çalışmaları gibi aktiviteler kısıtlanmış ve sporcunun takıma güvenli bir şekilde uyum sağlaması hedeflenmiştir.




**Şekil 4.7.** Oyuncunun yaralanmadan 50 gün sonraki görüntüsü  
(S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi)

Sporcunun yaralanmasından 120 gün sonra, sahaya dönüş testlerinden biri olan izokinetik kuvvet testi uygulamasının hemen ardından termal bir görüntü alınmış ve yaralanma bölgesinin teste verdiği tepki değerlendirilmiştir (Şekil 4.8). Ortalama sıcaklık farkı  $0,05^{\circ}\text{C}$ , minimum sıcaklık farkı  $0,41^{\circ}\text{C}$  ve maksimum sıcaklık farkı  $0,02^{\circ}\text{C}$  olarak ölçülmüştür. İzokinetik kuvvet testinde, sağ-sol kuvvet farkı %8'in altına düşen sporcunun, izokinetik antrenman gibi yoğun fiziksel gereksinimlerde bile termal simetrisini koruduğu gözlemlenmiştir. Bu bulgular doğrultusunda, sporcunun takım ile tüm aktivitelere katılmasına izin verilmiştir. Bu dönemde sporcu özellikle şut antrenmanlarına odaklanmıştır. Sahaya dönüş kriterlerini tamamlayan sporcu, takım ile 10 gün boyunca antrenmanlara katılmıştır.




**Şekil 4.8.** Oyuncunun yaralanmadan 120 gün sonra izokinetik testler sonrası görüntüsü  
(S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi)

130. günde, 10 günlük antrenman periyodu sonrasında alınan termal görüntülerde, ortalama sıcaklık farkının  $0,37^{\circ}\text{C}$ , minimum sıcaklık farkının  $0,32^{\circ}\text{C}$  ve maksimum sıcaklık farkının  $0,1^{\circ}\text{C}$  olduğu görülmüştür (Şekil 4.9). Sporcu, 10 günlük antrenman sürecinin ardından termal simetrisini koruduğu için müsabakaya katılmasına karar verilmiştir.



**Şekil 4.9.** Oyuncunun yaralanmadan 130 gün sonra saha antrenmanı sonrası görüntüsü  
(S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi)

Yaralanmanın 135. gününde, takımla birlikte antrenmanlarını sorunsuz bir şekilde sürdüren ve futbol maçına katılmasına karar verilen sporcu, maçta 30 dakika süre almıştır. Şekil 4.10'da maç sonrasında alınan termal görüntüde sporcunun ortalama sıcaklık farkının  $0,15^{\circ}\text{C}$ , minimum sıcaklık farkının  $0,43^{\circ}\text{C}$  ve maksimum sıcaklık farkının  $0,26^{\circ}\text{C}$  olduğu görülmüştür. Aynı zamanda, maç sonrasında da sporcunun termal simetrisini koruduğu tespit edilmiştir.



**Şekil 4.10.** Oyuncunun yaralanmadan 135 gün sonraki görüntüsü  
(S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi)

Bu çalışmada, RF yaralanması olan bir sporcunun rehabilitasyon programına verdiği tepkiler ve iyileşme sürecindeki günlük değişimlerin termografi ile nasıl gözlemlenebileceği belirlenmiştir. Sporcuların rehabilitasyon süreci boyunca incelenen termografik değerleri aşağıda sunulmuştur (Çizelge 4.1).

**Çizelge 4.1.** Oyuncuların rehabilitasyon süresi boyunca incelenen sıcaklık değerleri


| Görüntüleme Tarihi | Bölge | Ort.  | Min. Sıcaklık | Maks. Sıcaklık | Ort. Asimetri | Min. Asimetri | Maks. Asimetri |
|--------------------|-------|-------|---------------|----------------|---------------|---------------|----------------|
| Yaralanma Öncesi   | S1    | 27,40 | 21,72         | 31,20          | 0,34          | 0,41          | 1,61           |
|                    | S2    | 27,74 | 21,37         | 29,59          |               |               |                |
| Yaralanma Sonrası  | S1    | 31,79 | 23,81         | 33,73          | 0,70          | 0             | 0,14           |
|                    | S2    | 31,09 | 23,81         | 33,87          |               |               |                |
| 40. Gün            | S1    | 32,14 | 30,88         | 34,11          | 0,03          | 5,52          | 0,60           |
|                    | S2    | 32,11 | 25,36         | 34,71          |               |               |                |

|                 |    |       |       |       |      |      |      |
|-----------------|----|-------|-------|-------|------|------|------|
| <b>50. Gün</b>  | S1 | 33,43 | 32,27 | 35,59 | 0,59 | 2,25 | 0,13 |
|                 | S2 | 32,84 | 30,02 | 35,46 |      |      |      |
| <b>120. Gün</b> | S1 | 32,21 | 30,59 | 34,56 | 0,04 | 0,41 | 0,02 |
|                 | S2 | 32,17 | 31,00 | 34,54 |      |      |      |
| <b>130. Gün</b> | S1 | 33,92 | 29,77 | 35,53 | 0,37 | 0,32 | 0,10 |
|                 | S2 | 33,55 | 29,45 | 35,63 |      |      |      |
| <b>135. Gün</b> | S1 | 32,26 | 29,39 | 34,37 | 0,17 | 0,43 | 0,26 |
|                 | S2 | 32,09 | 29,82 | 34,11 |      |      |      |

Sporcularda rehabilitasyonun sonlandırılması, sahaya dönüş ve müsabakalara katılım gibi durumlarda net bir karar vermek genellikle zor olmaktadır. Elde edilen bulgular doğrultusunda, sporcunun rehabilitasyon sürecinin takibi ve antrenmanlara dönüş zamanı belirlenmesi üzerine çalışılmıştır. Termografinin, RF yaralanmalarının takibinde alternatif bir yöntem olarak kullanılabileceği görülmüştür (Bayrak ve diğ., 2021a).

#### **4.1.3. Egzersizin Etkisi Altında Kas Yaralanmalarının Tespitinde Termografi Yöntemi: Sartorius Kası Örneği**

Musculus sartorius, terzi kası olarak da bilinen, vücuttaki en uzun kastır ve yaklaşık 60 cm uzunluğundadır (Arıncı ve Elhan, 2020). Sartorius kası, spina iliaca anterior superiordan başlar ve tibia üzerinde sonlanır. Femoral sinir tarafından innerve edilen bu kas, kalça ve diz eklemlerinden geçtiği için, uyluğun fleksiyonu, abdüksiyonu ve dış rotasyonuna, aynı zamanda diz fleksiyondayken bacağın fleksiyonu ve iç rotasyonuna neden olur. Ancak, sartorius kası bu hareketlerin hiçbirini tek başına güçlü bir şekilde yapamaz; esasen bu hareketleri üreten diğer uyluk kaslarıyla birlikte çalışan bir sinerjist kas olarak görev yapmaktadır (Moore ve diğ., 2015). Musculus sartorius distalde pes anserinus yapısına katılır, ancak distal lifleri aynı zamanda tibia aponevrozuna da katılım gösterir (Şekil 4.11). Bu nedenle, bu bölge sartorius kasının muayenesinde klinik açıdan önemli bir alan olarak kabul edilir (Dziedzic ve diğ., 2014).



Şekil 4.11. Sartorius kası anatomisi (Sobotta, 2005)

Ayrıca, sartorius kasının motor kontrol açısından önemli bir kas olduğu da bilinmektedir (Mendis ve Hides, 2016). Futbolda üst uyluk yaralanmaları genellikle RF gibi quadriceps kas grubunu içerirken, sartorius kası yaralanmaları oldukça nadirdir (Malherbe, 2019).

#### 4.1.3.1. Vaka Sunumu


23 yaşında, 185 cm boyunda, 81 kg ağırlığında ve stoper mevkisinde oynayan Türkiye Süper Ligi sporcusu, antrenman sırasında sağ dizini kaldırırken uyluğunun üst kısmında ağrı hissettiğini belirtmiştir. Sporcu, hafif koşu (jogging) sırasında dizini kaldırırken ve özellikle çorap giyerken ağrının hissedildiği bölgenin üst uyluk olduğunu ifade etmiştir. Sol dizde benzer bir bulguya rastlanmamıştır. Dinlenme sırasında alınan termografi görüntüsünde belirgin bir asimetri gözlenmezken, aynı gün %30-40 dirençle 10 dakikalık bisiklet protokolü sonrasında alınan termografi görüntüsünde sartorius kas

bölgesinde sağ tarafta sıcaklık farkının anlamlı derecede arttığı tespit edilmiştir. Bunun üzerine sporcunun aynı gün MR görüntülemesi yapılmış ve 1. derece Sartorius kası yaralanması teşhisi konulmuştur.

Sporcu antrenmanlara devam etmesine rağmen sartorius kas yaralanması için tedavi başlatılmıştır. Antrenman sırasında dokunun korunması amacıyla kinezyo bantlama yöntemi kullanılmıştır. Bir hafta sonra, her iki tarafın sartorius bölgelerinde asimetri sona ermiş ve simetrik bir ısı haritası gözlenmiştir. Sporcu, simetri sağlandığı gün ağrılarının tamamen geçtiğini belirtmiştir.

#### **4.1.3.2. Araştırma Sonuçları ve Tartışma**

İlk gün ağrı hissettiğini belirten sporcunun dinlenme halinde alınan görüntüsünde yapılan incelemede, sartorius proksimal bölgesinde sol tarafın sağ tarafa kıyasla ortalama sıcaklık farkının  $0,36^{\circ}\text{C}$ , minimum sıcaklık farkının  $0,08^{\circ}\text{C}$  ve maksimum sıcaklık farkının ise  $0,8^{\circ}\text{C}$  daha yüksek olduğu tespit edilmiştir (Şekil 4.12). Bu durum, sporcunun sağ taraf sartorius proksimal bölgesinin gün boyunca korunmuş ve ağırlığın daha çok karşı tarafa verilmiş olabileceğini gösterebilir. Sartorius'un orta ve distal bölgelerinde, yaralanmanın olduğu sağ tarafın daha yüksek sıcaklık değerine sahip olduğu görülmüştür. Bu durum, yaralanma bölgesi olan üst kısmın korunurken, kasın diğer bölgelerinde gerilim yükünün arttığını göstermektedir.



**Şekil 4.12.** Antrenman öncesi dinlenme halinde alınan görüntü:

(a) proksimal bölge sıcaklık farkı, (b) orta bölge sıcaklık farkı, (c) distal bölge sıcaklık farkı  
(C1 Sağ taraf seçili bölge - C2 Sol taraf seçili bölge)

Sartorius'un orta bölgesindeki sıcaklık farkında ortalama farkın  $0,58^{\circ}\text{C}$ , minimum sıcaklık farkının  $0,53^{\circ}\text{C}$  ve maksimum sıcaklık farkının  $0,07^{\circ}\text{C}$  olduğu belirlenmiştir. Sartorius'un distal bölgesinde ise sağ-sol sıcaklık farkı ortalama  $0,41^{\circ}\text{C}$ , minimum sıcaklık farkı  $0,11^{\circ}\text{C}$  ve maksimum sıcaklık farkı  $0,55^{\circ}\text{C}$  olarak tespit edilmiştir.


Sporcunun kasını korumak, diğer bölgelerde artan gerilim etkilerini en aza indirmek ve kasın yük altındaki tepkisini doğru bir şekilde değerlendirmek amacıyla, 10 dakikalık bisiklet egzersizi sonrası görüntülemenin tekrarlanmasına karar verilmiştir.

Futbolcunun günlük yaşam aktivitelerini ağırlıklı olarak sağlıklı bacağına yüklenerek gerçekleştirmesi nedeniyle, antrenman öncesi alınan görüntüde sağlıklı tarafın sıcaklık değerinin daha yüksek olduğu gözlemlenmiştir. Ancak, sağ tarafta ağrı hisseden futbolcuda kas yırtığı şüphesi bulunmaktaydı. Bu durumdan dolayı termal görüntülerde sıcaklık asimetrisinde azalma görülebilmektedir. Bu tür yanıltıcı durumların önüne geçmek ve yaralanmayı daha kolay ve doğru bir şekilde tespit edebilmek için farklı bir yaklaşım gerekliliği ortaya çıkmıştır.

Bu çalışmada termografi ile birlikte kullanılan bisiklet egzersizi yaklaşımında, dinlenme sırasında alınan görüntüye ek olarak, yaralanma şüphesi bulunan kası uyuracak ancak yaralanma seviyesini artırmayacak şekilde her iki ekstremiteye eşit yük


veren bir egzersiz programı uygulanmıştır. Sartorius kası için, alt ekstremitelere simetrik yüklenme sağlayan 10 dakikalık bir bisiklet programı uygulanmıştır. Bu yaklaşımın temel amacı, yaralanmayı ilerletmeden kasların termal tepsiini doğru ölçmektir.

Yaralanmanın olduğu gün, 10 dakikalık bisiklet antrenmanı sonrasında alınan görüntünün incelenmesinde, sağ taraf sartorius kasında belirgin bir sıcaklık artışı ve sıcaklık asimetrisi tespit edilmiştir (Şekil 4.13).



**Şekil 4.13.** Antrenman sonrası alınan görüntü: **(a)** proksimal bölge sıcaklık farkı, **(b)** orta bölge sıcaklık farkı, **(c)** distal bölge sıcaklık farkı (C1 Sağ taraf seçili bölge - C2 Sol taraf seçili bölge)

Sporcu, tedavisine ve koruyucu kinezyo bant kullanımına bir hafta boyunca devam etmiş ve ağrısız bir şekilde antrenmanlarını tamamlamıştır. Saha antrenmanını gerçekleştirdikten sonra, termal görüntüsü yeniden alınmıştır (Şekil 4.14).



**Şekil 4.14.** 1 haftalık tedavinin ardından, ağrısız bir şekilde tamamlanan antrenman sonrasında alınan görüntü: **(a)** proksimal bölge sıcaklık farkı, **(b)** orta bölge sıcaklık farkı, **(c)** distal bölge sıcaklık farkı (C1 Sağ taraf seçili bölge - C2 Sol taraf seçili bölge)

Yaralanmadan bir hafta sonra ağrısız bir şekilde tamamlanan saha antrenmanının ardından alınan görüntüde sıcaklık simetrisinin yeniden oluştuğu gözlemlenmiştir. Sartorius'un proksimal bölgesinde ortalama sıcaklık farkının  $0,06^{\circ}\text{C}$ , minimum sıcaklık farkının  $0,05^{\circ}\text{C}$  ve maksimum sıcaklık farkının  $0,09^{\circ}\text{C}$  olduğu tespit edilmiştir. Sartorius orta bölgesindeki sıcaklık farkı ise ortalama  $0,13^{\circ}\text{C}$ , minimum  $0,07^{\circ}\text{C}$  ve maksimum  $0,09^{\circ}\text{C}$  olarak ölçülmüştür. Sartorius distal bölgesinde sağ-sol sıcaklık farkı ortalama  $0,03^{\circ}\text{C}$ , minimum  $0,07^{\circ}\text{C}$  ve maksimum  $0,10^{\circ}\text{C}$  olarak belirlenmiştir. Sartorius kas bölgesinde ağrı hissetmeyen sporcunun, 90 dakikalık antrenman sonrasında sıcaklık simetrisini koruduğu tespit edilmiştir. Bu bulgu, sporcunun ağrı şikayetlerinin termografik sonuçları ile uyumlu olduğunu göstermiştir. Bu çalışmada, ağrı hisseden ve antrenmanlara devam eden bir sporcunun yaralanması termografik yöntemle teşhis edilmiş ve tedavi süreci başlatılmıştır.

Sartorius kas yaralanmaları nadir görüldüğünden üst uyluk bölgesindeki diğer yaralanmalarla karıştırılabilmektedir. Termografik görüntüleme, kolay ve hızlı kullanımı sayesinde futbolcularda rutin inceleme imkanı sunarak bu tip yaralanmaların teşhisinde önemli rol oynamaktadır. Özellikle aşırı kullanım (overuse) türündeki

yaralanmalarda erken teşhis sağlayarak, sporcuların tanı, tedavi ve takip süreçlerini mümkün hale getirmektedir. Ancak, termal görüntüleme ile bu tür yaralanmaların tespitinde, sporcunun dinlenme ve antrenman sonrası alınan görüntülerinin farklılık gösterebileceği unutulmamalıdır. Sağlıklı tarafın koruyucu yük altında sıcaklık artışı gösterebileceği göz önünde bulundurulmalıdır. Bu tür yaralanmalarda, yaralanmanın şiddetini artırmayacak şekilde güvenli bir antrenman sonrası alınan görüntüler, gerçek sorunun daha güvenilir bir şekilde tespit edilmesine olanak sağlayacaktır. Sporcunun ağrıları ile alınan görüntülerin uyumluluğu göz önüne alındığında, termografinin bu tür kas yaralanmalarında bir rehabilitasyon takip aracı olarak kullanılabileceği düşünülmektedir. Bu tür durumlarda kas yırtığından şüpheleniliyorsa, olası bir yırtığın ilerlemesini önlemek adına, her iki tarafa da simetrik yükleme sağlayan bisiklet gibi düşük yoğunluklu egzersiz programları uygulanması ve bu egzersizlerin ardından termografik görüntülemenin tekrar edilmesi önerilmektedir (Bayrak ve diğ., 2024).


#### **4.1.4. Operatif Yolla Tedavi Edilen Proksimal Rektus Femoris Tendon Ruptürü Yaralanması Öyküsü Olan Sporcunun Antrenman Etkisi Altında Termografi ile Değerlendirilmesi**

RF kası, futbol sporunda daha hızlı koşma ve şut çekme gibi eylemler nedeniyle önemli bir yere sahiptir (Hasselman ve diğ., 1995). Ancak, RF kas yırtılması önceki bölümlerde bahsedildiği üzere sıklıkla gözden kaçan bir yaralanma türü olduğundan takip edilmesi zor bir yaralanmadır (Hughes IV ve diğ., 1995). Bu nedenle, iyileşme sürecini kısaltmak ve olası komplikasyonları önlemek açısından yaralanmanın düzenli takibi büyük önem taşımaktadır (Hawkins ve diğ., 2001).

##### **4.1.4.1. Vaka Sunumu**


31 yaşında, 189 cm boyunda ve 79 kg ağırlığında bir hücum oyuncusu, 2020 yılı mart ve nisan ayları arasında sağ rektus femoris bölgesinde iki yaralanma geçirmiştir. Aynı yıl mayıs ayında yapılan antrenmanda, sprint sırasında aniden oluşan ağrı ve yanma hissi nedeniyle antrenmanı tamamlayamamıştır. Yapılan incelemede, sağ RF kasının proksimal bölgesinde 3. derece yaralanma tespit edilmiştir. Sporcunun tedavisi cerrahi müdahale ile gerçekleştirilmiştir. Sporcu, 73 gün sonra antrenmanlara

başlamıştır. Ancak, termografi ile takip edilen futbolcu aynı bölgede tekrar bir yaralanma yaşamıştır.



**Şekil 4.15.** Antrenman öncesi termal görüntü ve RF kaslarındaki sıcaklık farkı (S1: sağ rektus bölgesi, S2: sol rektus bölgesi).

Antrenman öncesi yapılan değerlendirmede, sağ ve sol taraflar arasında ortalama sıcaklık farkının  $0,69^{\circ}\text{C}$ , minimum sıcaklık farkının  $0,70^{\circ}\text{C}$  ve maksimum sıcaklık farkının  $0,30^{\circ}\text{C}$  olduğu, sol tarafın daha yüksek sıcaklığa sahip olduğu belirlenmiştir (Şekil 4.15).



**Şekil 4.16.** Antrenman sonrası termal görüntü ve RF kaslarındaki sıcaklık farkı (S1: sağ rektus bölgesi, S2: sol rektus bölgesi).

Antrenman sonrası yapılan değerlendirmede, sağ ve sol taraflar arasındaki ortalama sıcaklık farkının sağ tarafta  $0,21^{\circ}\text{C}$  daha yüksek olduğu tespit edilmiştir.

Maksimum sıcaklık farkı ise 0,75°C olarak belirlenmiştir. Minimum sıcaklık farkının ise sol tarafta 0,19°C daha yüksek olduğu görülmüştür (Şekil 4.16).

#### 4.1.4.2. Araştırma Sonuçları ve Tartışma

Bu çalışmada, RF proksimal tendon yaralanma öyküsü bulunan ve cerrahi yöntemle sahalara dönen bir sporcunun antrenman programına verdiği tepki termografi yöntemiyle değerlendirilmiştir.

**Çizelge 4.2.** Futbolcu RF kaslarında antrenman öncesi ve sonrası sıcaklık farkı

| Vaka              | Ortalama    | Minimum     | Maksimum    |
|-------------------|-------------|-------------|-------------|
| Antrenman Öncesi  | 0,69        | 0,70        | 0,30        |
| Antrenman Sonrası | 0,21        | 0,19        | 0,75        |
| Sıcaklık Farkı    | <b>0,90</b> | <b>0,51</b> | <b>1,05</b> |

Çizelge 4.2’de antrenman öncesi ve sonrası değerlere bakıldığında, sağ ve sol taraflar arasındaki sıcaklık değişim farklarının ortalama 0,90°C, minimum 0,51°C ve maksimum 1,05°C olduğu görülmüştür. Bu durum, antrenman öncesi ve sonrası sağ ve sol taraf arasındaki sıcaklık farkının arttığını göstermektedir.

Elde edilen sonuçlar doğrultusunda, cerrahi tedavi ile iyileşen sporcunun termal tepkisinin değiştiği tespit edilmiştir. Yaralanma geçmişinin yaralanma riski üzerindeki etkisi göz önünde bulundurulduğunda, cerrahi tedavi yöntemiyle sahalara dönen sporcuların antrenman yüküne karşı düzenli olarak takip edilmesi gerektiği önerilmektedir. Sporcunun antrenman stresine uyum sağlayamadığı ve tekrar yaralandığı gözlemlenmiştir. Bu incelemelerden hareketle, termografi yönteminin, diğer görüntüleme yöntemlerine kıyasla antrenman yükünü değerlendirebilen bir görüntüleme yöntemi olduğu görülmektedir (Bayrak ve diğ., 2021a).

#### 4.1.5. Rektus Femoris Proksimal Yırtık Geçmiş Olan Sporcuların Antrenman Yüküne Verdikleri Tepkinin Termografi ile İzlenmesi

Bu çalışma, RF kasının farklı yaklaşımlarla tedavilerinin ardından antrenman yükünün sporcular üzerindeki etkisini termografi yöntemiyle değerlendirmiştir.

#### 4.1.5.1. Vaka 1


22 yaşındaki (172 cm, 72 kg) hücum oyuncusu, Türkiye Süper Ligi maçında ön uyluk bölgesinde hissettiği ağrı nedeniyle maçı tamamlayamamıştır. Maç sırasında sağ ayağıyla şut çekerken sol ayağının çime takılması sonucu sol quadriceps kasında aşırı gerilme meydana gelmiştir. Maç sonrası yapılan muayenede, sporcunun sağ ve sol tarafında sıcaklık farkı olduğu ve sol proksimal rektus femoris bölgesinde ağrı tespit edilmiştir. Sporcu, aktif kalça eklemi fleksiyona getirdiğinde ve kalça eklemi geriye çektiğinde yanma hissi yaşadığını belirtmiştir. Sol proksimal uyluk bölgesinde kas-tendon bütünlüğünün kaybıyla 3. derece kas zorlanması teşhisi konulmuş ve aynı tarihte yapılan MRG incelemesinde 3. derece rektus femoris yaralanması rapor edilmiştir. Sporcuya konservatif tedavi yöntemi uygulanmıştır. Rehabilitasyon sürecinden 72 gün sonra sporcunun antrenmanlara katıldığı ve sahalara döndüğü gözlemlenmiştir.

#### 4.1.5.2. Vaka 2

31 yaşında, 189 cm boyunda ve 79 kg ağırlığındaki bir hücum oyuncusu, sağ rektus femoris bölgesinde iki kez yaralanma yaşamıştır. Futbolcu antrenman sırasında sprint atarken ani bir ağrı ve yanma hissi nedeniyle antrenmanı tamamlayamamıştır. Yapılan incelemelerde, sağ RF kasının proksimal bölgesinde 3. derece yaralanma tespit edilmiştir. Sporcunun tedavisi cerrahi yöntemle gerçekleştirilmiş ve 73 gün sonra antrenmanlara başlamıştır.


#### 4.1.5.3. Araştırma Sonuçları ve Tartışma

İlk vakada antrenman öncesi yapılan değerlendirmede, sağ ve sol bacak RF kas bölgeleri arasındaki ortalama sıcaklık farkının sağ tarafın lehine 0,40°C olduğu, minimum sıcaklık farkının ise 0,57°C olduğu gözlemlenmiştir. Maksimum sıcaklık farkının ise sol tarafın lehine 0,11°C daha yüksek olduğu tespit edilmiştir (Şekil 4.17).



**Şekil 4.17.** Vaka 1 antrenman öncesi termal görüntüsü ve sıcaklık farkı  
(S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi)

Antrenman sonrası yapılan değerlendirmede, sağ ve sol RF kas bölgeleri arasındaki ortalama sıcaklık farkının sağ taraf lehine  $0,73^{\circ}\text{C}$  olduğu, minimum sıcaklık farkının ise  $1,02^{\circ}\text{C}$  olarak tespit edildiği görülmüştür. Maksimum sıcaklık farkının ise sol tarafın lehine  $0,29^{\circ}\text{C}$  daha yüksek olduğu belirlenmiştir (Şekil 4.18).




**Şekil 4.18.** Vaka 1 antrenman sonrası termal görüntüsü ve sıcaklık farkı  
(S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi)

Antrenman öncesi ve sonrası değerlere bakıldığında, sağ ve sol RF kas bölgeleri arasındaki ısı değişim farklarının ortalama  $0,33^{\circ}\text{C}$ , minimum  $0,45^{\circ}\text{C}$  ve maksimum


0,18°C olduğu görülmüştür. Bu durum, antrenman öncesi ve sonrası sağ ve sol taraf arasındaki farkın bu ölçüde açıldığını göstermektedir.

İkinci vakada antrenman öncesi yapılan değerlendirmede, sağ ve sol RF kas bölgeleri arasındaki ortalama sıcaklık farkının 0,69°C, minimum sıcaklık farkının 0,70°C ve maksimum sıcaklık farkının 0,30°C olduğu tespit edilmiştir (Şekil 4.19).



**Şekil 4.19.** Vaka 1 antrenman sonrası termal görüntüsü ve sıcaklık farkı (S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi).

Antrenman sonrası yapılan değerlendirmede, sağ ve sol RF kasları arasındaki ortalama sıcaklık farkının sağ taraf lehine 0,21°C, maksimum sıcaklık farkının ise 0,75°C olduğu belirlenmiştir. Minimum sıcaklık farkının ise sol taraf lehine 0,19°C daha yüksek olduğu tespit edilmiştir (Şekil 4.20).



**Şekil 4.20.** Vaka 1 antrenman sonrası termal görüntüsü ve sıcaklık farkı (S1: sağ taraf rektus bölgesi, S2: sol taraf rektus bölgesi).

Antrenman öncesi ve sonrası değerlere bakıldığında, sağ ve sol RF kas bölgeleri arasındaki ısı değişim farklarının ortalama  $0,90^{\circ}\text{C}$ , minimum  $0,51^{\circ}\text{C}$  ve maksimum  $1,05^{\circ}\text{C}$  olduğu görülmüştür. Bu durum, antrenman öncesi ve sonrası alınan görüntülerde sağ ve sol arasındaki sıcaklık farkının bu ölçüde arttığını göstermektedir.

Vaka 1 ve vaka 2'nin aynı antrenmana verdikleri tepkilerin farklı olduğu gözlemlenmiştir. Cerrahi tedavi ile iyileşen vaka 2'nin, antrenman yüküne karşı termal tepkisinin daha yüksek olduğu tespit edilmiştir.

Bu çalışmanın sonuçlarına göre, konservatif tedavi ile iyileşen sporcunun antrenmanın neden olduğu strese daha iyi uyum sağladığı görülmektedir. Bu çalışmada sunulan iki vakanın, RF proksimal yırtıklarıyla ilgili takip protokolünün uygulanması açısından gelecekteki literatür çalışmalarına katkı sağlaması beklenmektedir. Diğer yandan, farklı tedavi yöntemleriyle iyileşen bu iki vaka, aynı antrenmana verdikleri tepkileri değerlendirmek amacıyla termal kamera kullanılarak incelenmiştir. Yaralanma riski taşıyan vaka 2'nin, iki hafta içinde yeniden bir rektus femoris yaralanması yaşadığı gözlemlenmiştir (Bayrak ve diğ., 2023).

#### 4.1.6. Profesyonel Futbolcuların Egzersiz Planlaması İçin Kızılötesi Termografi Kullanımı

Bu çalışmada Türkiye Süper Ligi'nde oynayan aktif yaralanma öyküsü bulunan profesyonel futbolcular, sezon ortası hazırlık kampında kızılötesi termografi ile gözlemlenmiştir. Bu kampta, futbolcular antrenman maçları sonrasında termografi yöntemiyle değerlendirilmiştir. Antrenman sırasında oyuncuların egzersiz süreleri, kat ettikleri mesafeleri, +20 km/s ve +24 km/s sprintleri, maksimum hızları ve koşu dengesizlikleri hakkında bilgiler toplanmıştır. Özellikle daha önce yaralanma öyküsü bulunan 4 oyuncu (1. derece hamstring yaralanması, ayak altında bir yara, aşil tendiniti ve 2. derece menisküs yırtığı) birinci gün antrenman maçı sonrası ve ikinci gün termal görüntüleme ile incelenmiştir. İlk gün sonrasında 2 oyuncu dinlendirilirken, diğer 2 oyuncu ikinci gün farklı egzersizler yaparak termografi ile gözlemlenmiştir. Oyunculara ait bilgiler Çizelge 4.3'te sunulmuştur.

Çizelge 4.3. İzlenen futbolculara ait bilgiler

| Oyuncu   | Yaş | Boy (m) | Pozisyon      | Dominant Ayak |
|----------|-----|---------|---------------|---------------|
| Oyuncu 1 | 24  | 1,84    | Hücum         | Sol           |
| Oyuncu 2 | 31  | 1,85    | Defans        | Sağ           |
| Oyuncu 3 | 36  | 1,86    | Defans        | Sağ           |
| Oyuncu 4 | 29  | 1,80    | Sağ-Sol Kanat | Sol           |

##### 4.1.6.1. Araştırma Sonuçları ve Tartışma

Antrenmanın ilk gününde, oyuncularla ilgili antrenmana ait bilgiler kaydedilmiştir (Çizelge 4.4). Çizelge, oyuncuların kaç dakika egzersiz yaptığı, kaç metre koştuğu, kaç kez sprint hızına ulaştığı (sayı olarak verilmiştir) ve koşu dengesizliğini (örneğin, oyuncunun sağ bacağına daha fazla ve sert bastığı durumları) göstermektedir. Antrenman sonrasında oyuncular kızılötesi termografi ile incelenmiştir (Şekil 4.21). 1. derece hamstring zorlanma problemi olan 1. oyuncu, Şekil 4.21 a'da posterior olarak alınmış termografi görüntüsünde belirtilmiştir. Görüntüde, oyuncunun sağ hamstring bölgesinde bir ısı yayılımı ve artışı görülmektedir. Ayrıca, oyuncunun sağ bacağındaki

problem nedeniyle sol bacağına daha fazla yük verdiği için koşu dengesizliği de gözlemlenmiştir.


Şekil 4.21 b'de, 2. oyuncunun posterior termografi görüntüsünde sağ baldır bölgesinde bir ısı artışı tespit edilmiştir. Oyuncunun aşıl tendiniti problemi olduğu bilinmektedir. Koşu dengesizliği verileri, sağ aşıl tendonundaki problem nedeniyle oyuncunun sol bacağına daha fazla yük bindiğini göstermektedir.

Şekil 4.21 c'de, 2. derece menisküs yırtığı problemi olan 3. oyuncu yer almaktadır. Anterior olarak alınmış termografi görüntüsünde, sol diz kapağı çevresinde bir ısı artışı tespit edilmiştir. Koşu dengesizliği verileri, oyuncunun sol dizindeki problem nedeniyle sağ bacağına daha fazla yüklendiğini ortaya koymaktadır. Ayrıca, bu yaralanma nedeniyle oyuncunun yüksek sprint hızına ulaşamadığı gözlemlenmiştir.

Şekil 4.21 d'de, sağ ayağının altında bir yara bulunan 4. oyuncu incelenmiştir. Yara nedeniyle oyuncunun sol bacağına daha fazla baskı uyguladığı görülmüştür. Bu durum, sol bacağına ısı artışına yol açmıştır.

**Çizelge 4.4.** Antrenmanın ilk gününde oyunculardan toplanan bilgiler

| Oyuncu          | Süre (dk.) | Mesafe (m) | +20km/s | +24km/s | Maksimum   | Koşu         |
|-----------------|------------|------------|---------|---------|------------|--------------|
|                 |            |            | Sprint  | Sprint  | Hız (km/s) | Dengesizliği |
| <b>Oyuncu 1</b> | 55         | 6930       | 821     | 326     | 32,3       | %6 Sol       |
| <b>Oyuncu 2</b> | 55         | 6046       | 491     | 208     | 28,6       | %5 Sol       |
| <b>Oyuncu 3</b> | 55         | 6022       | 408     | 81      | 25,6       | %6 Sağ       |
| <b>Oyuncu 4</b> | 9          | 1950       | 505     | 42      | 25,6       | %2 Sağ       |




**Şekil 4.21.** İlk egzersiz sonrası termografik gözlem: a) 1. oyuncunun posterior termografi görüntüsü. Sağ hamstring bölgesinde ısı yayılımı ve artışı görülebilmektedir. b) 2. oyuncunun posterior termografi görüntüsü. Sağ baldır bölgesinde ısı farkı tespit edilebilmektedir. c) 3. oyuncunun anterior termografi görüntüsü. Diz kapağı çevresinde ısı artışı gözlemlenmiştir. d) 4. oyuncunun anterior termografi görüntüsü. Sol baldır bölgesindeki ısı artışı görülebilmektedir.

Gözlemin ardından, 1. ve 3. oyuncular ikinci gün dinlendirilmiş ve termografideki farklılıklar incelenmiştir. 2. ve 4. oyuncular ise antrenmana dahil edilmiş olup egzersiz bilgileri Çizelge 4.5'te görülebilmektedir. Egzersiz sonrasında tüm oyuncular kızılötesi termografi ile değerlendirilmiştir (Şekil 4.22).

**Çizelge 4.5.** Antrenmanın ilk gününde oyunculardan toplanan bilgiler

| Oyuncu   | Süre (dk.) | Mesafe (m) | +20km/s | +24km/s | Maksimum   | Koşu         |
|----------|------------|------------|---------|---------|------------|--------------|
|          |            |            | Sprint  | Sprint  | Hız (km/s) | Dengesizliği |
| Oyuncu 2 | 63         | 5340       | 17      | 3       | 24,8       | %3 Sol       |
| Oyuncu 4 | 63         | 6157       | 142     | 24      | 26,1       | %1 Sağ       |



**Şekil 4.22.** İkinci egzersiz sonrası termografik gözlem: a) 1. oyuncunun posterior termografi görüntüsü. Sağ hamstring bölgesinde ısı yayılımı ve artışı görülebilmektedir. b) 2. oyuncunun posterior termografi görüntüsü. Sağ baldır bölgesinde ısı farkı tespit edilmiştir. c) 3. oyuncunun anterior termografi görüntüsü. Diz kapağı çevresinde ısı artışı gözlemlenmiştir. d) 4. oyuncunun anterior termografi görüntüsü. Sol baldır bölgesindeki ısı artışı görülmektedir.

Her bir oyuncu için araştırma sonuçları aşağıda verilmiştir;

Oyuncu 1: Şekil 4.22 a'da, antrenman sonrası dinlenen 1. oyuncunun sağ hamstring bölgesindeki ısının azaldığı görülmektedir. İlk gün sağ ve sol hamstring arasındaki maksimum sıcaklık farkı  $1^{\circ}\text{C}$  olarak tespit edilirken, ikinci gün bu fark  $0,4^{\circ}\text{C}$ 'ye düşmüştür. Bu durum, 1. oyuncudaki 1. derece hamstring zorlanmasının dinlenme sayesinde iyileşmeye başladığını göstermektedir. Eğer oyuncu dinlenmeseydi, yaralanma kötüleşebilir veya iyileşme süresi uzayabilirdi.

Oyuncu 2: Şekil 4.22 b'de, 2. oyuncunun baldır probleminde hafif bir iyileşme olduğu görülmektedir. Oyuncu dinlendirilebilseydi, yaralanması daha iyi bir seviyeye gelebilirdi. İlk gün sağ ve sol baldır arasındaki maksimum sıcaklık farkı yaklaşık  $2,1^{\circ}\text{C}$  olarak tespit edilirken, ikinci gün bu fark  $0,3^{\circ}\text{C}$  olarak izlenmiştir. Ayrıca, egzersiz verilerinden oyuncunun koşu dengesizliğinin ilk gün sol bacakta %5 iken, ikinci gün sol bacakta %3'e düştüğü görülmektedir. Sprint sayıları ve maksimum hız verileri,

oyuncunun kendisini zorlamadığını ve bu durumun yaralanmasındaki hafif iyileşmeye katkı sağladığını göstermektedir.

Oyuncu 3: Şekil 4.22 c'de, 3. oyuncunun diz kapağı çevresindeki ısının iyileşme gösterdiği tespit edilmiştir. İlk gün sağ ve sol diz kapağı arasındaki sıcaklık farkı  $2,4^{\circ}\text{C}$  iken, ikinci gün bu fark  $1^{\circ}\text{C}$ 'ye düşmüştür. Bu durum, 1. oyuncuya benzer şekilde, 3. oyuncunun dinlendirilmesinin 2. derece menisküs yırtığı yaralanmasının kötüleşmesini engellediğini ve iyileşmeye yardımcı olduğunu göstermektedir. Ayrıca, koşu dengesizliği ile karşılaştırıldığında, sağ quadriceps bölgesindeki sıcaklık seviyesinin arttığı ve sol tarafın azaldığı görülmektedir. Bu durum, oyuncunun daha az ve daha fazla kullandığı kasların tespit edilmesine ve fizyoterapistin rehabilitasyon programını planlamasına yardımcı olmuştur.

Oyuncu 4: Şekil 4.22 d'de, 4. oyuncunun sol bacağındaki ısının azaldığı ve bunun sağ ayağındaki yaralanmanın iyileşmesinden kaynaklandığı görülmektedir. İlk gün sıcaklık farkı  $0,9^{\circ}\text{C}$  iken, ikinci gün bu fark  $0,2^{\circ}\text{C}$  olarak tespit edilmiştir. Ayrıca, oyuncunun daha rahat egzersiz yapabildiği ve kendisini daha fazla zorlayabildiği gözlemlenmiştir. Bunun yanı sıra, oyuncunun koşu dengesi de hafif iyileşme göstermiştir.

Sonuç olarak, kızılötesi termografinin oyuncunun bir sonraki maçta oynayıp oynamaması veya hangi egzersizleri yapması gerektiği konusunda karar vermek için kullanılabileceği görülmüştür. Tüm yaralanmalar gözlemlendikten sonra, beklendiği gibi, kızılötesi termografinin yaralanma, yorgunluk ve kas problemlerini tespit edebileceği sonucuna varılmıştır. Antrenman ve sıcaklık verileri incelendiğinde oyuncunun yaralanmaya yatkın olup olmadığının öngörülmesine yardımcı olabileceği sonucuna varılmıştır. Ayrıca, bu çalışma, kızılötesi termografi ile koşu dengesizliği bilgisi arasındaki etkileşimi göstermiştir. Literatürde bu etkileşimi ele alan çok fazla çalışma bulunmamaktadır. Bu çalışma sayesinde, dinlenmenin yaralanma üzerindeki etkinliği de gözlemlenmiştir.

#### 4.2. Termal Görüntülerden Kas Segmentasyonu Çalışmaları

Futbolcularda termografi ile yaralanmaların tespit edilmesinin önemi literatürdeki çalışmalarca kanıtlanmıştır. Bir önceki bölümde gerçekleştirilen çalışmalarda futbolcuların antrenman öncesi ve sonrası termal görüntülerinin değerlendirilmesi yaralanmaların erken tespiti ve rehabilitasyon sürecinin takibi için

önem arz etmektedir. Bir futbol takımının kadro genişliği göz önünde bulundurulduğunda bütün futbolcuların termal görüntülerinin yetkin bir kişi tarafından incelenmesi zaman almaktadır. Ayrıca bu incelemenin sonuçları süreci yürüten kişinin değerlendirmesine bağlı olduğundan gözden kaçan noktalar olabilmektedir. Bu sebeple kas bölgelerinin otomatik olarak segmente edilmesi gözlemciye kolaylık sağlamaktadır. Bu bağlamda futbolcu alt ekstremitte termal görüntülerinden kas bölgelerinin segmentasyonu için U-Net, FPN, Linknet ve PSPNet derin öğrenme mimarilerinin kullanıldığı bir çalışma gerçekleştirilmiştir.

#### **4.2.1. Termal Görüntülemeye Alt Ekstremitte Kas Segmentasyonu için Derin Öğrenme Modellerinin Değerlendirilmesi**

Bu çalışma, termografi görüntüleri kullanarak futbolcularda alt ekstremitte kaslarının segmentasyonu için derin öğrenme modellerinin etkinliğinin araştırılmasını kapsamaktadır. Özellikle U-Net, PSPNet, Linknet ve FPN modellerinin performansı karşılaştırılarak alt ekstremitte kaslarının termal görüntüler üzerinden hassas bir şekilde segmente edilme başarısı değerlendirilmiştir. Türkiye Süper Ligi'nde mücadele eden profesyonel futbolcuların alt ekstremitte termal görüntülerinin kullanıldığı çalışmada 9 farklı kas bölgesi belirlenmiştir: Üst adductor, quadriceps rektus, quadriceps vastus, vastus medialis, diz (patellar), gastrocnemius ve soleus, tibialis anterior ve fibularis, ayak bileği ve ayak (Şekil 2.1). Bu bölgeler, anatomik atlası dayanarak seçilmiştir. Bu dokuz bölgenin segmentasyonu U-Net, PSPNet, Linknet ve FPN derin öğrenme mimarileri kullanılarak gerçekleştirilmiştir (Şekil 3.3, 3.4, 3.5, 3.6).


##### **4.2.1.2 Araştırma Bulguları ve Tartışma**

9 kas bölgesine ait segmentasyon sonuçlarının başarısını değerlendirmek için IoU (Intersection over Union), F1 Skoru, Kesinlik (Precision) ve Duyarlılık (Recall) kriterleri kullanılmıştır. Bu değerlendirmelere ilişkin sonuçlar Çizelge 4.6'da sunulmuştur.

Çizelge 4.6. Her kas bölgesine ve mimariye ait segmentasyon sonuçları


| Üst Adductor                 | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
|------------------------------|-----------|----------|---------|----------|------------|
| UNET                         | 0,0047973 | 0,99652  | 0,99826 | 0,99869  | 0,99782    |
| PSPNET                       | 0,01168   | 0,99232  | 0,9614  | 0,99668  | 0,99561    |
| LINKNET                      | 0,0049213 | 0,99648  | 0,99824 | 0,99846  | 0,99802    |
| FPN                          | 0,0040235 | 0,99636  | 0,99817 | 0,99924  | 0,99711    |
| Quadriceps Rectus            | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,0088036 | 0,99171  | 0,99584 | 0,99888  | 0,999282   |
| PSPNET                       | 0,013787  | 0,98906  | 0,99449 | 0,99674  | 0,99228    |
| LINKNET                      | 0,010008  | 0,99102  | 0,99549 | 0,99857  | 0,99243    |
| FPN                          | 0,007669  | 0,9933   | 0,99664 | 0,99808  | 0,99521    |
| Quadriceps Vastus            | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,006764  | 0,9939   | 0,99694 | 0,9989   | 0,99499    |
| PSPNET                       | 0,010832  | 0,99157  | 0,99577 | 0,99604  | 0,99552    |
| LINKNET                      | 0,007984  | 0,99365  | 0,99681 | 0,99814  | 0,99549    |
| FPN                          | 0,0075698 | 0,99349  | 0,99673 | 0,99864  | 0,99484    |
| Vastus Medialis              | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,0037516 | 0,99727  | 0,99863 | 0,99873  | 0,99853    |
| PSPNET                       | 0,0068536 | 0,99488  | 0,99743 | 0,99668  | 0,99819    |
| LINKNET                      | 0,0041785 | 0,99697  | 0,99848 | 0,99866  | 0,9983     |
| FPN                          | 0,0037125 | 0,99696  | 0,99848 | 0,99877  | 0,99819    |
| Diz                          | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,007558  | 0,99413  | 0,99705 | 0,99836  | 0,99575    |
| PSPNET                       | 0,012517  | 0,98864  | 0,99428 | 0,99747  | 0,99112    |
| LINKNET                      | 0,008531  | 0,99346  | 0,99672 | 0,99816  | 0,99528    |
| FPN                          | 0,0058014 | 0,9952   | 0,99759 | 0,99871  | 0,99648    |
| Gastrocnemius, Soleus        | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,0043135 | 0,99687  | 0,99843 | 0,99888  | 0,99798    |
| PSPNET                       | 0,0063228 | 0,9565   | 0,99782 | 0,99726  | 0,99838    |
| LINKNET                      | 0,0041512 | 0,99707  | 0,99853 | 0,99876  | 0,9983     |
| FPN                          | 0,0036518 | 0,997199 | 0,99859 | 0,99886  | 0,99833    |
| Tibialis anterior, Fibularis | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,0054936 | 0,99599  | 0,99799 | 0,99871  | 0,99728    |
| PSPNET                       | 0,006755  | 0,99533  | 0,99766 | 0,99722  | 0,9981     |
| LINKNET                      | 0,0061396 | 0,99643  | 0,99821 | 0,99787  | 0,99856    |
| FPN                          | 0,0047623 | 0,99639  | 0,99819 | 0,99795  | 0,99844    |
| Ayak Bileği                  | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,0021456 | 0,99823  | 0,99912 | 0,99951  | 0,99872    |
| PSPNET                       | 0,0036669 | 0,99702  | 0,99851 | 0,99927  | 0,99775    |
| LINKNET                      | 0,0025119 | 0,99774  | 0,99887 | 0,9997   | 0,99804    |
| FPN                          | 0,0020342 | 0,9982   | 0,9991  | 0,99962  | 0,99858    |
| Ayak                         | Kayıp     | IoU      | F1      | Kesinlik | Duyarlılık |
| UNET                         | 0,0035398 | 0,99714  | 0,99857 | 0,99965  | 0,99748    |
| PSPNET                       | 0,012956  | 0,98902  | 0,99448 | 0,99954  | 0,98947    |
| LINKNET                      | 0,0025007 | 0,99818  | 0,99909 | 0,99928  | 0,9989     |
| FPN                          | 0,0020176 | 0,99834  | 0,99917 | 0,99953  | 0,99881    |

Her kas bölgesi için segmentasyon işleminin görsel sonuçları Şekil 4.23-4.31'da gösterilmektedir.




**Şekil 4.23.** Üst adductor bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN




**Şekil 4.24.** Quadriceps rectus bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN




Şekil 4.25. Quadriceps vastus bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN




Şekil 4.26. Vastus medialis bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN




Şekil 4.27. Diz bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN




Şekil 4.28. Gastrocnemius, soleus bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN




Şekil 4.29. Tibialis anterior, fibularis bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN



Şekil 4.30. Ayak bileği bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN



Şekil 4.31. Ayak bölgesi için segmentasyon sonuçları:

a) U-Net, b) PSPNet, c) Linknet, d) FPN

Araştırma sonuçları, FPN ve U-Net modellerinin termal görüntüler üzerinden alt ekstremite kaslarının segmentasyonunda en başarılı sonuçları verdiğini göstermiştir. Özellikle IoU ve F1 skorları açısından bu modeller, diğerlerine göre daha yüksek performans sergilemiştir. Bölge bazında yapılan analizlerde ise ayak bölgesinin, yapısal özellikleri nedeniyle segmentasyonda en başarılı sonuçları verdiği belirlenmiştir. Bu çalışma, spor hekimliği ve tıbbi görüntüleme alanında önemli bir yere sahiptir ve PSPNet, Linknet, U-Net ve FPN gibi derin öğrenme modellerinin termal görüntülerde alt ekstremite kaslarını doğru bir şekilde segmente etme yeteneklerini inceleyerek, sporculardaki yaralanma analizi ve değerlendirmesi için gelişmiş araç ve tekniklere duyulan kritik bir ihtiyacı ele almaktadır.

Spor hekimliğinde bir görüntüleme yöntemi olarak termografinin entegrasyonu, kas yaralanmalarının izlenmesi ve teşhisinde umut verici bir yöntem olarak zaten kendini göstermiştir. Ancak, futbolcularda artan yaralanma oranları ve buna bağlı finansal maliyetler, daha etkili izleme ve önleyici tedbirlerin gerekliliğini vurgulamaktadır.

Neticede, derin öğrenme modellerinin termal görüntü segmentasyonundaki başarılı uygulamaları, yaralanma oranlarını azaltmaya, iyileşme sürelerini kısaltmaya ve

sporcuların performanslarını optimize etmeye katkıda bulunabilir. Bu araştırma, spor hekimliği alanında gelecekteki gelişmeler için bir temel sağlayarak, sporcuların özel ihtiyaçlarına göre uyarlanmış gelişmiş görüntüleme teknikleri ve kişiselleştirilmiş tedavi planlarının geliştirilmesine olanak tanımaktadır (Ergene ve diğ., 2023).

#### **4.3. Termal Görüntülerden Yaralanma Sınıflandırması**

Önceki bölümlerde ifade edildiği üzere, futbolcuların termal görüntülerinin analizi genellikle uzman kişiler tarafından yapılmakta ve geniş takım kadroları nedeniyle bu süreçte zaman alıcı olmakta, hata yapma riski artmakta ve analizlerde tutarlılık sağlamak zorlaşmaktadır. Bu zorlukları aşmak amacıyla, görüntü işleme ve derin öğrenme mimarileri kullanılarak segmente edilen kas bölgeleri üzerinde yaralanma tespitine yönelik çalışmalar gerçekleştirilmiştir. Bu çalışmalara ilişkin detaylar aşağıda sunulmaktadır.


##### **4.3.1. Profesyonel Futbolcularda Yaralanmaların Termografi ve Görüntü İşleme ile İzlenmesi**

Bu çalışmada, profesyonel futbolcularda alt ekstremita kas yaralanmalarını tespit etmek ve iyileşme süreçlerini izlemek amacıyla kızılötesi termografi ve görüntü işleme algoritmaları kullanılmıştır. Çalışmanın amacı, sporcularda kas yaralanmalarının erken teşhis edilmesi ve iyileşme sürecinin izlenmesinde fizyoterapistlere destek sağlamak ve böylece gereksiz yaralanmaların önüne geçilmesine katkıda bulunmaktır. Üç farklı futbolcu üzerinde yapılan bu ön çalışmada, yaralanmaların ve dinlenme sonrası iyileşme süreçlerinin termografik görüntülerle değerlendirilmesi gerçekleştirilmiştir.

##### **4.3.1.1 Kullanılan Görüntü İşleme Algoritması**


Araştırma kapsamında, Türkiye Süper Ligi'nde oynayan üç profesyonel futbolcunun alt ekstremita kasları termografi kullanılarak gözlemlenmiştir. Bu oyuncuların mevcut yaralanmaları şu şekildedir:

1. 1. derece hamstring gerilmesi (Şekil 4.32 a),
2. Aşıl tendiniti (Şekil 4.32 b),
3. Ayağın altında yara (Şekil 4.32 c).



**Şekil 4.32.** Aktif yaralanmaları bulunan futbolcular: **a)** Oyuncu 1'in posterior termografisi. Sağ hamstringde inflamasyon ve ısı artışı gözlemlenmektedir. **b)** Oyuncu 2'nin posterior termografisi, sağ baldırda bir ısı farkı olduğunu göstermektedir. **c)** Oyuncu 3'ün anterior termografisi, sol baldırda ısı artışını göstermektedir.

Oyuncuların aktif yaralanmaları bilindiğinden, fizyoterapistler futbolculara 1 günlük dinlenme süresi vermiştir. Bir günlük dinlenme sonrasında futbolcular tekrar gözlemlenmiş ve Şekil 4.33'teki sonuçlar elde edilmiştir. Sonuçlarda, tüm oyuncularda inflamasyon ve sıcaklık seviyelerinin azaldığı gözlemlenmiştir. Ayrıca, ısı dengesizliği tespit edilmemiştir. Tüm oyuncularda yaralanma bölgesinde ağrının azaldığı belirtilmiştir.




**Şekil 4.33.** Bir günlük dinlenme sonrası oyuncular: **a)** Oyuncu 1'in posterior termografisi. Sağ hamstringdeki inflamasyon ve ısı azalmıştır. **b)** Oyuncu 2'nin posterior termografisi, sağ baldırdaki sıcaklık farkının kaybolduğunu göstermektedir. **c)** Oyuncu 3'ün anterior termografisi, sol baldırdaki sıcaklığın azaldığını göstermektedir.

Görüntü işleme algoritmasının ilk adımında, termografik renk paletinin RGB değerleri belirlenerek renklerin üst ve alt sınırları tespit edilmiştir (Şekil 4.34).




**Şekil 4.34.** Termal renk paleti

Bir sonraki adımda, renk paletinden elde edilen RGB değerlerine göre belirlenen eşik değerleriyle daha yüksek sıcaklık gösteren alanlar belirlenmiştir. Renk uzayına dayalı eşikleme içeren çoğu görüntü işleme uygulamasında, genellikle HSV renk uzayı kullanılmaktadır. Bu tür uygulamalarda HSV kullanımının amacı, görüntü üzerindeki parlaklık ve ortam ışığının etkisini ortadan kaldırmaktır (Mohd Ali ve diğ., 2013). Ancak, bu çalışmada RGB renk uzayının tercih edilmesinin nedeni, kullanılan kızılötesi sensörün görüntüleri ışığa bağımlı olmaksızın, yalnızca yayılan ısıya bağlı olarak dijitalleştirilmesidir. Şekil 4.35'te eşikleme ve ikili (binary) maske oluşturulmasına ilişkin bir örnek gösterilmektedir.



Şekil 4.35. a) Orijinal görüntü, b) Alt ve üst RGB değerlerine göre eşiklenmiş görüntü (maske).

Daha sonra, daha sıcak bölgelerin pikselleri (Şekil 4.35 b) orijinal görüntüden (Şekil 4.35 a) çıkarılmıştır. Ardından, orijinal görüntü gri tonlamaya dönüştürülmüş ve çıkarılan renkli pikseller, sıcak bölgelerin renklendirilerek görüntülenmesi amacıyla birleştirilmiştir. Bu sayede, fizyoterapistlerin sıcak bölgeleri daha kolay inceleyebilmesi ve sorunu teşhis edebilmesi sağlanmıştır (Şekil 4.36).




Şekil 4.36. a) Renkli ve sıcak bölgelerin net bir şekilde gösterildiği birleştirilmiş nihai görüntü

#### 4.3.1.2 Araştırma Sonuçları ve Tartışma

Oyuncu 1'de birinci derece hamstring problemi bulunmaktadır. Hamstring problemi, kas üzerinde inflamasyona ve ısı artışına neden olmaktadır. Bu problem gözlemlenirken inflamasyon bölgesinin boyutu ve bölgedeki sıcaklık dikkate alınmıştır.

Şekil 4.37 a'da görüldüğü üzere bir miktar ısı artışı bulunmaktadır. Ancak, Şekil 4.37 b'de ısı artışının nerede olduğu ve hangi kasların etkilendiği açıkça görülebilmektedir.




Şekil 4.37. Tedavi ve dinlenme öncesinde Oyuncu 1 için algoritma sonucu (a, b).  
Tedavi ve dinlenme sonrasındaki sonuçlar (c, d).

Şekilde, oyuncunun sağ iç hamstring bölgesinde inflamasyon olduğu görülmektedir. Bu sonucun ardından fizyoterapistler, gerekli tedaviyi doğrudan bu bölgeye uygulamışlardır. Ayrıca, yapılan tıbbi muayeneler sonucunda tedavinin başarılı olduğu belirtilmiştir. Tedavi sonrasında oyuncu dinlenmiş ve yeniden gözlemlenmiştir (Şekil 4.37 c, d). Şekilde, dinlenme ve tedavinin başarıyla sonuçlandığı ve sağ iç hamstring bölgesindeki ısının normale döndüğü gösterilmektedir. Yalnızca küçük bir alan gözlemlenmiştir. Bu nedenle oyuncu, hafif bir tedavi sonrasında iyileşme sağlayabilmiştir. Sonuçlar, eğer oyuncu antrenman yapmaya devam etseydi yaralanmanın daha kritik hale geleceğini ve yaklaşık 20 gün antrenman ve maç kaçırabileceğini göstermiştir.

Oyuncu 2'de aşıl tendiniti problemi bulunmaktadır. Bu problem, posterior ayak bileği ve anterior iç baldır bölgesinde inflamasyona ve ısı artışına neden olmaktadır. Bu durum gözlemlenirken inflamasyon bölgesinin boyutu ve sıcaklığı dikkate alınmıştır. Şekil 4.38 a'da her iki bacakta da bir miktar sıcaklık artışı olduğu görülmektedir. Ancak, Şekil 4.38 b'de hangi bacağın sorunlu olduğu, sıcaklık artışının nerede bulunduğu ve hangi kasların etkilendiği net bir şekilde gözlemlenmiştir. Sorunun sağ bacakta olduğu

ve oyuncunun sağ iç baldırında bir sıcaklık artışı olarak kendini gösterdiği tespit edilmiştir. Sol bacakta görülen sıcaklık artışının nedeni ise oyuncunun sağ bacağına ağrı hissetmesi üzerine sağ bacağına zorlamaktan kaçınarak sol bacağına daha fazla kullanmasıdır. Bu durum, sol bacakta yansıyan bir ısı artışına yol açmıştır.




Şekil 4.38. Tedavi ve dinlenme öncesinde Oyuncu 2 için algoritma sonucu (a, b).  
Tedavi ve dinlenme sonrasındaki sonuçlar (c, d).

Fizyoterapistler diğer oyuncuda da olduğu gibi gerekli tedaviyi başlatmış ve oyuncu bir gün dinlenmiştir. Tedavi sonrasında oyuncu dinlenmiş ve yeniden gözlemlenmiştir (Şekil 4.38 c, d). Şekilde, dinlenme ve tedavinin başarılı olduğu, sağ iç baldırdaki ısının normale döndüğü ve yansıyan ısının kaybolduğu görülmektedir. Bu sayede, oyuncu hafif bir tedavi ile yeniden iyileşme göstermiştir. Sonuçlar, bu küçük tedavinin oyuncuyu daha ciddi bir durumdan kurtardığını göstermektedir. Zira, bu yaralanma ilerlemiş olsaydı, oyuncunun 50 güne kadar tedavi görmesi gerekebilirdi.

Oyuncu 3'ün sağ ayağının altında bir yara bulunmaktaydı. Şekil 4.39 (a, b)'de, sol baldırda bir ısı artışı gözlemlenmiştir. Bunun nedeni, Oyuncu 2'nin durumunda da açıklandığı gibi, yansıyan ısı etkisidir. Sağ ayağındaki ağrı nedeniyle oyuncunun hareketlerinde bir dengesizlik oluşmuş ve ayaklarına dengesiz bir şekilde basmıştır. Bu durum, yansıyan ısının ve kızılötesi termografinin önemini göstermektedir, çünkü normal bir tedavi sürecinde sadece yara tedavi edilecek ve bacak göz ardı edilecekti.

Ancak, kızılötesi termografi ve kullanılan algoritma sayesinde, fizyoterapistler bacağı da tedavi uygulamış ve oyuncu bir gün dinlenmiştir.



Şekil 4.39. Tedavi ve dinlenme öncesinde Oyuncu 3 için algoritma sonucu (a, b).

Tedavi ve dinlenme sonrasındaki sonuçlar (c, d).

Tedavi sonrasında oyuncu dinlenmiş ve yeniden gözlemlenmiştir (Şekil 3.39 c, d). Şekilde, dinlenme ve tedavinin başarılı olduğu, sağ iç baldırdaki ısının normale döndüğü ve yansıyan ısının kaybolduğu görülmektedir. Sonuç olarak, oyuncu hafif bir tedavi ile iyileşme göstermiştir. Sonuçlar, eğer oyuncu antrenman yapmaya devam etseydi veya bacaklardaki kas sorunu gözden kaçırılmış olsaydı, yaralanmanın daha ciddi bir hal alacağını ve oyuncunun 30 güne kadar maç ve antrenman kaçırabileceğini göstermiştir.

Sonuçlar, kızılötesi termografi ve görüntü işlemenin tanı desteği açısından önemini açık bir şekilde göstermiştir. Bu algoritma kullanılmamış olsaydı, oyuncuların sorunlarının daha ciddi yaralanmalara dönüşme ihtimali bulunmaktaydı. Bu durum, oyuncuların maç ve antrenmanları kaçırmalarına, tedavi masraflarının artmasına ve takımın başarısının azalmasına neden olabilirdi. Bu çalışmanın bir diğer önemi, algoritmanın ve elde edilen sonuçların profesyonel tıbbi personel tarafından doğrulanmış olmasıdır.

Bu çalışmanın literatüre katkıları şunlardır: Spor hekimliğinde ve özellikle profesyonel futbolcular üzerinde kızılötesi termografi kullanımıyla ilgili çok fazla çalışma bulunmamaktadır. Bu çalışma kızılötesi termografi ve görüntü işlemenin spor hekimliği ile mühendisliği birleştirdiği, profesyonel futbolcular üzerinde gerçekleştirilen ilk disiplinler arası çalışmalardan biridir. Bu çalışma, fizyoterapistler ve futbol kulüpleri için yaralanmaların tespitinde tanı desteği sağlayan görüntü işlemenin büyük bir öneme sahip olduğunu kanıtlamaktadır (Ergene ve diğ., 2020).

#### **4.3.2 Profesyonel Futbolcularda Termal Görüntülerden Hamstring Yaralanmalarının Tespiti İçin Derin Öğrenme Modellerinin Kullanımı**

Hamstring kası yaralanmaları futbolcuların en sık yaşadığı sakatlıklardan biridir. Yapılan çalışmalarda futbolcuların yaşadığı yaralanmaların yaklaşık %75'inin alt ekstremitelerde meydana geldiği, bu oran içinde %30'unun hamstring bölgesini de içeren uyluk bölgesinde gerçekleştiği rapor edilmiştir (Forsythe ve diğ., 2022). Görülme sıklığı göz önünde bulundurulduğunda hamstring kası yaralanmalarının tespit edilmesi futbol kulüpleri için önem taşımaktadır. Bundan dolayı tez çalışması kapsamında hamstring yaralanmalarının termografi ile tespiti için derin öğrenme yaklaşımları geliştirilmiştir.

Termal görüntüleme ile yaralanma tespitinin en büyük dezavantajlarından biri, yöntemin teşhis koyan kişinin yorumuna açık olması, kimi zaman yaralanmaların gözden kaçabilmesi ve görüntülerin tek tek analiz edilmesinin zaman alıcı olmasıdır. Geniş bir kadroya sahip futbol takımının termal görüntülerinin bir fizyoterapist tarafından analiz edilmesi oldukça zaman almaktadır. Bu sorunun önüne geçmek, yaralanma tespitindeki başarıyı artırmak ve spor hekimliği uzmanlarını desteklemek amacıyla, bu çalışmada, profesyonel futbol oyuncularının alt ekstremitelerinden alınan termal görüntüler üzerinden kas segmentasyonu ve yaralanma tespitine yönelik bir derin öğrenme algoritması geliştirilmiştir. Çalışmada, termografi ile kas bölgesinin otomatik segmentasyonu ve ardından bu segmentasyon sonucu elde edilen kas bölgesinin yaralanma durumunun sınıflandırılması gerçekleştirilmiştir.

Literatürde yapılan çalışmalar incelendiğinde, termal görüntülerden yaralanma tespiti için gerekli kas bölgesinin segmentasyonunu gerçekleştiren ve segmente edilen bölgeyi sınıflandırarak yaralanma tespiti yapan uçtan uca bir algoritma bulunmamaktadır. Bu çalışmada, profesyonel futbolcuların alt ekstremitelerinde termal

görüntülerinden hamstring kas bölgesinin U-Net mimarisi ve EfficientNetB3 altyapısı ile segmente edilmesinin, ardından Densenet, Resnet, VGG, EfficientNet mimarileri ve varyasyonları kullanılarak sınıflandırma işlemi gerçekleştirilmiştir. Daha sonra, bu mimarilerin sonuna Özellik Piramidi eklenerek görüntülerden daha fazla özellik çıkarılmış ve toplamda 20 mimarinin sınıflandırma sonuçları karşılaştırılmıştır.


Görüntüleme işlemi egzersiz öncesi ve sonrası gerçekleştirilmiştir. Egzersiz sırasında sağlıklı oyuncular rutin antrenmanlarını yapmışlardır. Yaralı oyuncular için ise sadece bisiklet egzersizi uygulanmış, yaralı kas korunarak egzersiz sonrası görüntüleme için kasın uyarılması sağlanmıştır. Toplamda, 35 profesyonel futbolcudan 320 termal görüntü elde edilmiştir. Bu 320 görüntü arasında, aktif hamstring yaralanması bulunan 9 futbolcu ve 26 sağlıklı futbolculardan elde edilen toplam 35 görüntü sınıflandırma işlemi için seçilmiştir. Veri sayısının yetersizliği nedeniyle döndürme, genişlik ve yükseklik kaydırma, yatay çevirme ve yakınlaştırma gibi veri artırımı yöntemleri uygulanarak veri seti 720 görüntüye genişletilmiştir. Bu süreç, yaralı futbolculara ait sınırlı veri nedeniyle oluşabilecek tutarsızlıkların önlenmesini amaçlamıştır.

Sınıflandırma ve segmentasyon işlemleri sırasında önceden eğitilmiş herhangi bir mimari kullanılmamıştır. Veriler sınıflandırılırken 5 katlı çapraz doğrulama yöntemi uygulanmış; 620 eğitim, 40 test ve 40 doğrulama verisi kullanılmıştır. Yaralı verilere yönelik olarak, aktif yaralanmaları olan futbolcuların verileri kullanılmıştır. Yaralanmaların doğrulaması, profesyonel spor hekimleri ve fizyoterapistler tarafından kreatin kinaz testleri, izometrik testler ve MR görüntüleme yöntemleriyle gerçekleştirilmiştir.

#### 4.3.2.1 Hamstring Segmentasyonu İçin Kullanılan Model

Çalışmada segmentasyon işlemi, profesyonel futbolcuların alt ekstremitte termal görüntülerinden hamstring kas bölgelerinin otomatik olarak çıkarılması için gerçekleştirilmiştir. Segmentasyon için önceki bölümlerde kullanılan U-Net, PSPNet, Linknet ve FPN modelleri arasından U-Net mimarisi kullanılmıştır (Şekil 3.3). U-Net ve Linknet'in sade ve sınırlı kapasiteye sahip donanımlarda kullanım imkanından dolayı bu iki model üzerine yoğunlaşmıştır. Çizelge 4.6'daki başarı oranları göz önünde bulundurulduğunda ise U-Net tercih edilmiştir. Amaç, termal görüntülerde hamstring kas bölgesinin doğru bir şekilde ayrıştırılarak sınıflandırma için uygun bir giriş


oluşturulmasıdır. Segmentasyon işlemleri sonucunda, hamstring kas bölgesi termal görüntülerden yüksek doğruluk oranlarıyla ayrıştırılmıştır (Şekil 4.40).



Şekil 4.40. Segmente edilen hamstring bölgesi

#### 4.3.2.2 Hamstring Yaralanması Sınıflandırması İçin Kullanılan Modeller

Çalışmada sınıflandırma süreci, segmentasyon adımıyla elde edilen hamstring kas bölgelerinin yaralı ya da sağlıklı olarak sınıflandırılmasını sağlamak amacıyla gerçekleştirilmiştir. Sınıflandırma işlemleri sırasında farklı derin öğrenme mimarileri test edilmiş ve sonuçlar karşılaştırılmıştır. Bu süreçte kullanılan temel modeller arasında Densenet, ResNet, VGG, EfficientNet ve bu mimarilerin varyasyonları (VGG16-19, Resnet50-101-152, Densenet121-169-201, EfficientnetB0-B1) kullanılmıştır (Şekil 3.7, 3.8, 3.9, 3.10). Buna ek olarak mimarilerin sonuna özellik piramidi (FPN) eklenerek her sınıfın detayları yakalanmış ve yaralı ve sağlıklı bölgeler sınıflandırılmıştır. Sınıflandırma işlemi için segmentasyon sonucunda elde edilen kas bölgeleri kullanılmıştır. Veri seti toplamda 720 görüntüden oluşmuştur. Bu görüntüler, veri artırımı yöntemleri (döndürme, genişlik-yükseklik kaydırma, yatay çevirme ve yakınlaştırma) ile genişletilmiştir. Veri seti, %80 eğitim, %10 doğrulama ve %10 test verisi olacak şekilde ayrılmıştır. 5 katlı çapraz doğrulama yöntemi kullanılarak modellerin performansı değerlendirilmiştir. Toplamda 20 mimari ile sınıflandırma işlemi gerçekleştirilmiş ve sonuçları karşılaştırılmıştır. Şekil 4.41’de önerilen sistemin blok diyagramı yer almaktadır.



**Şekil 4.41.** Alt ekstremitte termal görüntülerinden kas segmentasyonu ve yaralanma tespiti için önerilen sistem

#### 4.3.2.3 Araştırma Sonuçları

Segmentasyon işlemleri sonucunda, hamstring kas bölgesi termal görüntülerden yüksek doğruluk oranlarıyla ayrıştırılmıştır. Elde edilen segmentasyon maskeleri, sınıflandırma adımı için etkili bir temel sağlamış ve modelin genel başarısına katkıda bulunmuştur. Bu bölüm, termal görüntülerin otomatik işlenmesi ve analiz edilmesi için hızlı ve güvenilir bir yöntem sunarak, manuel etiketleme sürecindeki hataları azaltmıştır. Segmentasyon sonuçlarının başarısı, Kayıp (Loss), IoU, F1, Kesinlik (Precision) ve Duyarlılık (Recall) değerlerine göre ölçülmüştür. Her bir kas bölgesi, Şekil 4.40'ta gösterildiği şekilde segmente edilmiş ve sonuçlar Çizelge 4.7'da sunulmuştur.

**Çizelge 4.7.** Segmentasyon Sonucu

| Değerlendirme Kriteri | Sonuç    |
|-----------------------|----------|
| Kayıp                 | 0,019164 |
| IoU                   | 0,99219  |
| F1                    | 0,99608  |
| Kesinlik              | 0,99521  |
| Duyarlılık            | 0,99696  |

Bu çalışmada, Şekil 3.40'ta gösterilen segmente edilmiş hamstring bölgelerinde yaralanma olup olmadığını belirlemek amacıyla 20 farklı derin öğrenme mimarisi ile sınıflandırma yapılmıştır. Sınıflandırma işlemi, Çizelge 4.8'de görüldüğü üzere toplam 20 farklı mimariyle gerçekleştirilmiş ve sonuçları verilmiştir.

Çizelge 4.8. Sınıflandırma Sonuçları

| Model              | Doğruluk (%) | Kesinlik | Duyarlılık | F1    |
|--------------------|--------------|----------|------------|-------|
| Densenet121        | 61,6         | 0,594    | 0,621      | 0,607 |
| Densenet169        | 60,3         | 0,971    | 0,559      | 0,710 |
| Densenet201        | 60,1         | 0,989    | 0,557      | 0,713 |
| Resnet50           | 25,9         | 0,351    | 0,296      | 0,322 |
| Resnet101          | 54,4         | 0,914    | 0,525      | 0,667 |
| Resnet152          | 51,0         | 0,966    | 0,505      | 0,663 |
| VGG16              | 56,3         | 0,237    | 0,680      | 0,352 |
| VGG19              | 65,7         | 0,466    | 0,755      | 0,576 |
| EfficientnetB0     | 83,9         | 1,000    | 0,756      | 0,861 |
| EfficientnetB1     | 81,0         | 1,000    | 0,725      | 0,840 |
| Densenet121+FPN    | 57,4         | 1,000    | 0,540      | 0,701 |
| Densenet169+FPN    | 60,1         | 1,000    | 0,556      | 0,715 |
| Densenet201+FPN    | 58,3         | 1,000    | 0,545      | 0,706 |
| Resnet50+FPN       | 56,6         | 0,894    | 0,540      | 0,673 |
| Resnet101+FPN      | 56,7         | 0,894    | 0,541      | 0,674 |
| Resnet152+FPN      | 49,3         | 0,900    | 0,496      | 0,640 |
| VGG16+FPN          | 54,9         | 0,818    | 0,496      | 0,617 |
| VGG19+FPN          | 63,9         | 0,960    | 0,584      | 0,726 |
| EfficientnetB0+FPN | 80,1         | 0,997    | 0,717      | 0,834 |
| EfficientnetB1+FPN | 81,0         | 1,000    | 0,725      | 0,840 |

| Densenet121     | Tahmin   |          | Densenet169    | Tahmin |          | Densenet201        | Tahmin |          | Resnet50           | Tahmin |          |
|-----------------|----------|----------|----------------|--------|----------|--------------------|--------|----------|--------------------|--------|----------|
|                 | Yaralı   | Sağlıklı |                | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |
| Hedef           | Yaralı   | 223      | 127            | Hedef  | Yaralı   | 82                 | 268    | Hedef    | Yaralı             | 75     | 275      |
|                 | Sağlıklı | 142      | 208            |        | Sağlıklı | 10                 | 340    |          | Sağlıklı           | 4      | 346      |
| Resnet101       | Tahmin   |          | Resnet152      | Tahmin |          | VGG16              | Tahmin |          | VGG19              | Tahmin |          |
|                 | Yaralı   | Sağlıklı |                | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |
| Hedef           | Yaralı   | 61       | 289            | Hedef  | Yaralı   | 19                 | 331    | Hedef    | Yaralı             | 311    | 39       |
|                 | Sağlıklı | 30       | 320            |        | Sağlıklı | 12                 | 338    |          | Sağlıklı           | 267    | 83       |
| EfficientnetB0  | Tahmin   |          | EfficientnetB1 | Tahmin |          | Densenet121+FPN    | Tahmin |          | Densenet169+FPN    | Tahmin |          |
|                 | Yaralı   | Sağlıklı |                | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |
| Hedef           | Yaralı   | 237      | 113            | Hedef  | Yaralı   | 217                | 133    | Hedef    | Yaralı             | 52     | 298      |
|                 | Sağlıklı | 0        | 350            |        | Sağlıklı | 0                  | 350    | Hedef    | Sağlıklı           | 0      | 350      |
| Densenet201+FPN | Tahmin   |          | Resnet50+FPN   | Tahmin |          | Resnet101+FPN      | Tahmin |          | Resnet152+FPN      | Tahmin |          |
|                 | Yaralı   | Sağlıklı |                | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |
| Hedef           | Yaralı   | 58       | 292            | Hedef  | Yaralı   | 83                 | 267    | Hedef    | Yaralı             | 84     | 266      |
|                 | Sağlıklı | 0        | 350            |        | Sağlıklı | 37                 | 313    | Hedef    | Sağlıklı           | 37     | 313      |
| VGG16+FPN       | Tahmin   |          | VGG19+FPN      | Tahmin |          | EfficientnetB0+FPN | Tahmin |          | EfficientnetB1+FPN | Tahmin |          |
|                 | Yaralı   | Sağlıklı |                | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |                    | Yaralı | Sağlıklı |
| Hedef           | Yaralı   | 117      | 233            | Hedef  | Yaralı   | 111                | 239    | Hedef    | Yaralı             | 212    | 138      |
|                 | Sağlıklı | 51       | 229            |        | Sağlıklı | 14                 | 336    | Hedef    | Sağlıklı           | 1      | 349      |
|                 |          |          |                |        |          |                    |        | Hedef    | Yaralı             | 217    | 133      |
|                 |          |          |                |        |          |                    |        |          | Sağlıklı           | 0      | 350      |

Şekil 4.42. Sınıflandırma sonuçlarının karmaşıklık matrisi

Şekil 4.42’de verilen karmaşıklık matrisi incelendiğinde, en iyi sonucun EfficientNetB1+FPN kombinasyonu ve EfficientNetB0 ile elde edildiği görülmektedir. Çoğu mimarinin sağlıklı kas bölgelerini sınıflandırmada başarılı olduğu, ancak bazı mimarilerin yaralı kas bölgelerini doğru şekilde sınıflandırabildiği gözlemlenmiştir. Gerçek veri sayısının artırılması ve yapay olarak artırılmış veri oranının azaltılmasıyla bu sorunun önüne geçilebileceği açıktır. Ana mimarilerin FPN ile birleştirilmesi ve çıkarılan özellik sayısının artırılması, mimarinin başarı oranını önemli ölçüde

iyileştirmiştir. EfficientNetB1+FPN kombinasyonundan sonra EfficientNet varyasyonları ile en iyi sonuçlar elde edilmiştir. Başarı oranı ve görüntü başına 2,5 saniyelik sakatlık tespit süresi göz önüne alındığında, bu çalışmada önerilen algoritma, fizyoterapistler için başarılı ve hızlı bir tanı destek mekanizması sunmaktadır.

#### 4.3.2.4 Tartışma

Tez çalışmasında, futbolcuların alt ekstremitelerden hamstring kas bölgesi segmentasyonu gerçekleştirme ve segmente edilen kas bölgesinin yaralı olup olmadığını sınıflandırmak için derin öğrenme tabanlı bir algoritma önerilmiştir. Kas bölgesi U-Net kullanılarak segmente edilmiş ve IoU, F1, kesinlik (Precision) ve duyarlılık (Recall) değerlendirme metriklerine göre yaklaşık %99 başarı oranı elde edilmiştir. Daha sonra segmente edilen bölgeler Densenet, ResNet, VGG, EfficientNet ve bunların varyasyonlarıyla sınıflandırılmıştır. Mimarilerin son katmanına FPN eklenerek başarı oranı artırılmıştır. En iyi sınıflandırma sonuçlarının EfficientNet varyasyonlarıyla elde edildiği gözlemlenmiştir. Ayrıca, FPN ile birleştirildiğinde tüm mimarilerin daha iyi performans gösterdiği görülmüştür.

Segmentasyon sonuçları, literatürdeki benzer çalışmalarla karşılaştırıldığında başarılı sonuçlar elde edilmiştir. Hamstring kas segmentasyonuna yönelik doğrudan bir çalışma bulunmaması nedeniyle farklı kas bölgelerine ilişkin karşılaştırmalar yapılmıştır. Bununla birlikte, önerilen yöntem, U-Net ve DeepLabV3+ gibi diğer derin öğrenme yaklaşımlarının farklı kas bölgelerinde yapılan çalışmalardaki performansıyla karşılaştırıldığında, önerilen yöntemin başarısını ortaya koymaktadır.

Çalışma alanları ve kullanılan görüntüleme yöntemlerindeki farklılıklar segmentasyon sonuçlarını etkileyebilecek bir faktör olmasına rağmen, bu çalışmada %99 oranında bir başarı elde edilmiştir. Literatürde yer alan benzer çalışmaların segmentasyon başarı oranları incelendiğinde, en yüksek başarının %97 ile sınırlı kaldığı görülmektedir. Bu bağlamda, önerilen yöntemin literatüre kıyasla üstün bir performans sergilediği söylenebilir (Sudha ve diğ., 2017; Bougrine ve diğ., 2019; Hakim ve Awale, 2022; Özdil ve Yılmaz, 2022; Andrés López ve diğ., 2024). Önerilen yöntemin segmentasyon sonuçları ve literatürdeki çalışmaların karşılaştırması Çizelge 4.9'da sunulmuştur.

**Çizelge 4.9.** Önerilen segmentasyon yönteminin literatürle karşılaştırılması.

| <b>Çalışma</b>                         | <b>Segmentasyon<br/>Metodu</b>                | <b>Segmente<br/>Edilen Bölge</b> | <b>Doğruluk (%)</b> |
|----------------------------------------|-----------------------------------------------|----------------------------------|---------------------|
| <b>Sudha ve diğ.<br/>(2017)</b>        | Morfolojik<br>Operatörler ve Otsu<br>Eşikleme | Ayak Tabanı                      | 92,8                |
| <b>Bougrine ve diğ.<br/>(2019)</b>     | FCN                                           | Ayak Tabanı                      | 96,1                |
| <b>Bougrine ve diğ.<br/>(2019)</b>     | SegNet                                        | Ayak Tabanı                      | 97,2                |
| <b>Bougrine ve diğ.<br/>(2019)</b>     | U-Net                                         | Ayak Tabanı                      | 74,3                |
| <b>Andrés López ve<br/>diğ. (2024)</b> | DeepLabV3+                                    | Baldır (Calf)                    | 85,5                |
| <b>Önerilen Metot</b>                  | U-Net                                         | Hamstring                        | 99,6                |

Literatürde sınıflandırma ve yaralanma tespiti üzerine yapılan diğer çalışmalarla karşılaştırıldığında, önerilen EfficientNetB0 ve EfficientNetB1+FPN kombinasyonu umut verici sonuçlar sunmuştur. Bu çalışmada, literatürdeki çalışmalarla benzer başarı oranları elde edilmiştir (Jin ve diğ., 2013; Wang ve diğ., 2021; Bardhan ve diğ., 2022; Shobayo ve diğ., 2022; Trejo-Chavez ve diğ., 2022; Andrés López ve diğ., 2024; Mummaneni ve diğ., 2024; Özdil ve Yilmaz, 2024; Voinea ve diğ., 2024). Ancak, literatürdeki çalışmaların farklı vücut bölgelerinde farklı rahatsızlıkların veya yaralanmaların tespiti için kullanıldığı göz ardı edilmemelidir. Karşılaştırma Çizelge 4.10’da sunulmuştur (Ergene ve diğ., 2024).

Çizelge 4.10. Önerilen sınıflandırma yönteminin literatürle karşılaştırılması

| Çalışma                     | Sınıflandırma Metodu     | Sınıflandırılan Bölge | Görüntüleme Tekniği | Doğruluk (%) |
|-----------------------------|--------------------------|-----------------------|---------------------|--------------|
| Voinea ve diğ. (2024)       | ResNet                   | Ön Çapraz Bağ         | MRG                 | 97,14        |
| Jin ve diğ. (2013)          | Destek Vektör Makinaları | Diz Osteoartriti      | Termografi          | 85,49        |
| Bardhan ve diğ. (2022)      | Destek Vektör Makinaları | Diz Yaralanması       | Termografi          | 90,0         |
| Trejo-Chavez ve diğ. (2022) | ESA                      | Diz Yaralanması       | Termografi          | 95,09        |
| Shobayo ve diğ. (2022)      | Çok Katmanlı Perseptron  | El Bileği Kırığı      | Termografi          | 77,5         |
| Önerilen Metot              | EfficientnetB0           | Hamstring Yaralanması | Termografi          | 83,9         |
| Önerilen Metot              | EfficientnetB1 + FPN     | Hamstring Yaralanması | Termografi          | 81,0         |


#### 4.3.3 Hamstring Yaralanmasının Belirlenmesinde Prototip ve Siyam Ağlarının Kullanımı

Termal görüntülerden yaralanma tespiti üzerine literatürde birçok çalışma bulunmasına rağmen, yetersiz ve dengesiz veri setleri üzerinde yapılan çalışmalar oldukça sınırlıdır. Bir futbol takımında çok sayıda oyuncu bulunabilir ve sağlıklı görüntülerin elde edilmesi genellikle kolaydır. Ancak, oyunculardan yaralı futbolcu verilerine her zaman ulaşmak mümkün olmamaktadır. Bu durum dengesiz bir veri setine yol açmaktadır. Derin öğrenme mimarilerinin dengesiz veri setlerinde başarısız olabileceği bilinmektedir. Çalışmada bu sorunun önüne geçilmek için Prototip Ağları ve Siyam Ağları kullanılmıştır. Futbolcuların hamstring kaslarına ait termal verilerden yaralanmaların tespiti başarılı bir şekilde gerçekleştirilmiştir. Sınıflandırma sürecinde termal görüntüler değil, sayısal termal veriler kullanılmıştır. Bu yöntem, görüntü verilerinin işlenmesindeki karmaşıklığı azaltırken, sınıflandırma sürecinin hızını ve doğruluğunu artırmıştır. Sayısal termal verilerin kullanımı, özellikle büyük veri setlerinde analiz süreçlerini optimize ederek daha etkili bir yaralanma tespit sistemi

sunmaktadır. Böylelikle, termografi ile yapılan sınıflandırma işlemlerinde daha pratik ve güvenilir bir yaklaşım geliştirilmiştir.

#### 4.3.3.1 Sınıflandırma İçin Kullanılan Modeller

Toplamda, 25 profesyonel futbolcuyu kapsayan veri setinde, 16 sağlıklı ve 9 yaralı oyuncuya ait 25 termal görüntü elde edilmiştir. Daha sonra, veri artırma yöntemleri uygulanmıştır. Bu yöntemler arasında döndürme, genişlik ve yükseklik kaydırma, yatay çevirme ve yakınlaştırma yer almaktadır. Modellerde kullanılan ikiz ağ yapısı nedeniyle, sınıflardaki veri sayısının eşit veya birbirinin katı olması gerekmektedir. Bu nedenle, veri artırma işlemleri sonrasında toplamda 540 veri (360 sağlıklı ve 180 yaralı) oluşturulmuştur. Hamstring kas bölgesine ait termal görüntülerin ve verilerin bir örneği Şekil 4.43'te sunulmuştur.



Şekil 4.43. Örnek termal görüntü ve sıcaklık verileri

Sınıflama başarımını test etmek amacıyla 5 katlı çapraz doğrulama yöntemi uygulanmıştır. Yaralı sınıf için, yaralanmaları profesyonel spor hekimleri tarafından doğrulanmış futbolcuların termal görüntüleri kullanılmıştır. Ancak, futbol takımlarında sınırlı sayıda yaralanma yaşanması, yaralı oyunculara ait veri sayısının düşük kalmasına ve yetersiz, dengesiz bir veri seti oluşmasına neden olmuştur. Bu sorunu çözmek için, Prototipik Ağları ve Siyam Ağları gibi özel derin öğrenme mimarilerinden faydalanılmıştır (Şekil 3.11, 3.12). Bu mimariler, özellikle sınırlı veriyle çalışmayı gerektiren az örnekli öğrenme (few-shot learning) uygulamaları için etkili bir yaklaşım sunmaktadır. Böylece, veri setindeki dengesizliklerin üstesinden gelinmiş ve sınıflandırma başarısı artırılmıştır (Snell ve diğ., 2017). Siyam Ağları, iki veri örneği arasındaki benzerlikleri karşılaştırarak yaralanma gibi durumların tespiti için güçlü bir

yaklaşım sunarken, Prototip Ağlar her sınıf için bir prototip hesaplayarak sınıflandırma sürecini kolaylaştırır. Bu yöntemler sayesinde, dengesiz ve yetersiz veri seti problemlerinin üstesinden gelinmiş ve sınıflandırma işlemleri daha başarılı hale getirilmiştir. Yaralanmaların doğrulama süreci, takımın profesyonel spor hekimleri ve fizyoterapistleri tarafından gerçekleştirilmiş olup, bu süreçte kreatin kinaz verileri, izometrik testler ve MRG kullanılmıştır.


#### 4.3.3.2 Araştırma Sonuçları ve Tartışma

Termografik veriler üzerinde gerçekleştirilen az örnekli öğrenme (few-shot learning) çalışmasında, her iki mimari de sınıflandırma konusunda başarılı sonuçlar elde etmiştir. Bu başarı, sınırlı veri setleriyle çalışmaya yönelik etkili bir çözüm sunduklarını göstermektedir. Sınıflandırma sonuçları Çizelge 4.11’de sunulmuştur.

Çizelge 4.11. Sınıflandırma sonuçları

| Model           | Doğruluk (%) | Kesinlik | Duyarlılık | F1   |
|-----------------|--------------|----------|------------|------|
| Siyam Ağları    | 94,0         | 1        | 0,82       | 0,90 |
| Prototip Ağları | 97,78        | 0,93     | 1          | 0,96 |

Şekil 4.44'te verilen karmaşıklık matrisinde, en iyi sonucun %97,78 doğruluk oranı ile Prototip Ağları kullanılarak elde edildiği gözlemlenmiştir. Siyam Ağları ve Prototip Ağlar ile, yetersiz ve dengesiz veri seti durumunda dahi termal verilerden yararlanarak yaralı hamstring kas bölgesinin sınıflandırılmasının mümkün olduğu gösterilmiştir.



Şekil 4.44. Sınıflandırma sonuçlarının karmaşıklık matrisleri

Görüntü işleme ve derin öğrenme destekli yaralanma tespiti algoritmalarının başarılı sonuçlar verdiğini gösteren çalışmalar bulunmaktadır. Ancak, bu çalışmaların çoğunda yeterli ve dengeli veri setleri kullanılmıştır. Derin öğrenme modellerinin eğitim sürecinde, dengesiz ve yetersiz veri setlerinin zayıf eğitim sonuçlarına yol açabileceği bilinmektedir. Yaralı futbolculardan yeterli sayıda termografik veri elde etmenin zorluğu göz önüne alındığında, dengeli bir veri setiyle bir derin öğrenme modeli eğitmek her zaman mümkün olmayabilir. Bu çalışma, yetersiz ve dengesiz veri seti varlığında Siyam Ağları ve Prototip Ağların termografik verilerden kas yaralanmalarını tespit etmede önemli bir başarı gösterdiğini ortaya koymaktadır.

Literatürde sınıflandırma ve yaralanma tespiti üzerine yapılan diğer araştırmalarla karşılaştırıldığında, bu çalışmada önerilen yöntemler başarılı sonuçlar vermiştir. Çalışmada, literatürdeki çalışmalara kıyasla daha yüksek başarı oranları elde edilmiştir (Jin ve diğ., 2013; Wang ve diğ., 2021; Bardhan ve diğ., 2022; Shobayo ve diğ., 2022; Trejo-Chavez ve diğ., 2022; Ergene ve diğ., 2024; Özdil ve Yılmaz, 2024; Voinea ve diğ., 2024) Ancak, literatürdeki çalışmaların vücudun farklı bölgelerinde çeşitli rahatsızlıkların veya yaralanmaların tespitine odaklandığı unutulmamalıdır. Karşılaştırma Çizelge 4.12’de sunulmuştur.

Çizelge 4.12. Önerilen sınıflandırma yönteminin literatürle karşılaştırılması

| Çalışma                     | Sınıflandırma Metodu     | Sınıflandırılan Bölge | Görüntüleme Tekniği | Doğruluk (%) |
|-----------------------------|--------------------------|-----------------------|---------------------|--------------|
| Voinea ve diğ. (2024)       | ResNet                   | Ön Çapraz Bağ         | MRG                 | 97,14        |
| Jin ve diğ. (2013)          | Destek Vektör Makinaları | Diz Osteoartriti      | Termografi          | 85,49        |
| Bardhan ve diğ. (2022)      | Destek Vektör Makinaları | Diz Yaralanması       | Termografi          | 90,0         |
| Trejo-Chavez ve diğ. (2022) | ESA                      | Diz Yaralanması       | Termografi          | 95,09        |
| Shobayo ve diğ. (2022)      | Çok Katmanlı Perseptron  | El Bileği Kırığı      | Termografi          | 77,5         |
| Ergene ve diğ. (2024)       | EfficientnetB0           | Hamstring Yaralanması | Termografi          | 83,9         |
| Ergene ve diğ. (2024)       | EfficientnetB1 + FPN     | Hamstring Yaralanması | Termografi          | 81,0         |
| Önerilen Metot              | Siyam Ağları             | Hamstring Yaralanması | Termografi          | 94,0         |
| Önerilen Metot              | Prototip Ağları          | Hamstring Yaralanması | Termografi          | 97,78        |

Önceki çalışmada Çizelge 4.12'te görüldüğü üzere, EfficientNet ve FPN kullanılarak hamstring yaralanması tespiti için sınıflandırma gerçekleştirilmiştir. Ancak, bu sınıflandırma termal görüntüler üzerinden yapılmıştır. Veri eksikliği ve dengesiz veri seti nedeniyle, sonuçlar tatmin edici olmasına rağmen başarı oranı daha da artırılabilir olarak görülmüştür (Ergene ve diğ., 2024). Bu çalışmada ise, sınıflandırmanın başarı oranını artırmak amacıyla Prototip Ağlar ve Siyam Ağları kullanılmıştır. Ayrıca, sınıflandırma termografik sıcaklık verisi kullanılarak gerçekleştirilmiştir. Önceki çalışmalardan farklı olarak, yöntem yetersiz ve dengesiz veri seti sorununu çözerek kapsamlı bir yaralanma tespit algoritması sağlamaktadır.

Sonuç olarak, yetersiz ve dengesiz veri seti kullanılarak termal verilerden derin öğrenme ile yaralanma tespiti amacıyla kas sınıflandırmasını ileriye taşıyan bu çalışmanın, profesyonel futbolcular için yaralanma tespiti ve rehabilitasyon planlaması

alanında büyük bir etki yaratacağına inanılmaktadır. Ayrıca, bu çalışmanın gelecekteki araştırma çabalarına yeni fırsatlar sunarak alanında önemli bir katkı sağlaması beklenmektedir.

#### **4.3.4 Profesyonel Futbolcularda Alt Ekstremitte Yaralanmalarının Kızılötesi Termografi ile Sınıflandırılmasında Kolmogorov-Arnold Ağlarının Kullanımı**

Son yıllarda, termografi ve derin öğrenme yöntemleri kullanılarak yaralanma sınıflandırması üzerine birçok çalışma gerçekleştirilmiştir. Bu çalışmaların büyük bir kısmı makine öğrenimi ve geleneksel derin öğrenme mimarileri ile yürütülmüş olsa da bu çalışmada Kolmogorov-Arnold Ağı (KAN) kullanılmıştır. KAN, diğer mimarilere kıyasla önemli avantajlar sunan, nispeten yeni bir yöntemdir. Teorik temelleri 1950'lere dayanmasına rağmen, derin öğrenme bağlamındaki uygulamaları ve modern algoritmalarla entegrasyonu son yıllarda gelişmiştir. Bu bağlamda, KAN ile futbolcuların hamstring kaslarına ait termografik veriler kullanılarak yaralanmaların etkili bir şekilde tespit edilmesi hedeflenmiştir. Kolmogorov-Arnold Ağı, daha az parametre kullanarak karmaşık fonksiyonları modellemede son derece etkilidir. Bu, performanstan ödün vermeden hesaplama verimliliğini artırmaktadır. Bu yenilikçi yaklaşım, termografik görüntülerde yaralanma sınıflandırması alanında önemli bir potansiyel sergilemekte ve termografi ile yaralanma tespitinde ortaya çıkan yeni metodolojilerden birini temsil etmektedir.

Bu çalışmada, profesyonel futbolcuların alt ekstremitte termal görüntülerinden hamstring yaralanmalarının tespiti için Kolmogorov-Arnold Ağı kullanılmıştır. Çalışma, yaralanmaların erken evrede tespit edilmesi ve rehabilitasyon süreçlerinin etkili bir şekilde yönetilmesi için karar destek mekanizmaları sağlamayı amaçlamaktadır. Mevcut yetersiz ve dengesiz veri setleriyle başarılı bir şekilde çalışabilme yeteneği nedeniyle Kolmogorov-Arnold Ağı, sınırlı veriyle çalışırken etkili bir yöntem olarak öne çıkmaktadır.

##### **4.3.4.1 Sınıflandırma İçin Kullanılan Model**

Çalışmada Toplamda, 30 profesyonel futbolcudan 320 termal görüntü toplanmıştır. Bu görüntüler arasından, aktif hamstring yaralanması olan 9 futbolcu ile 20 sağlıklı futbolcudan elde edilen toplam 29 görüntü sınıflandırma işlemi için

belirlenmiştir. Sınıflandırma sürecinde, yaralı oyuncuların sınırlı verileri nedeniyle veri artırma yöntemleri (dönme, yatay çevirme, yükseklik ve genişlik kaydırma, yakınlaştırma gibi) uygulanarak veri seti 540 görüntüye genişletilmiştir. Sınıflandırmada transfer öğrenme yöntemleri veya önceden eğitilmiş mimariler kullanılmamıştır. Başarı oranını artırmak için 5 katlı çapraz doğrulama yöntemi uygulanmıştır. Doğrulanmış yaralanmaları olan oyuncular çalışmaya dahil edilmiş olup, yaralanma doğrulama işlemleri takımın profesyonel spor hekimleri ve fizyoterapistleri tarafından gerçekleştirilmiştir. Bu doğrulama sürecinde kreatin kinaz ölçümleri, izometrik testler ve MRG değerlendirmeleri kullanılmıştır. Sınıflandırma işlemi için Kolmogorov-Arnold Ağı tercih edilmiştir. Karmaşık çok değişkenli fonksiyonları daha basit bileşenlere ayırarak, hesaplama verimliliğini artırırken modelleme parametrelerini azaltması sayesinde az veri ile sınıflandırma işlemlerinde başarılı olmaktadır. Bundan dolayı az miktarda yaralanma verisine sahip bir termal görüntü setinde sınıflandırma görevi Kolmogorov-Arnold Ağı için uygun bir çalışma niteliği taşımaktadır.

#### 4.3.4.2 Araştırma Sonuçları ve Tartışma

Çalışma sonucunda sınıflandırma işleminin başarısı doğruluk, F1, kesinlik ve duyarlılık değerlerine göre ölçülmüştür. Kolmogorov-Arnold Ağı, %93,1 doğruluk oranıyla başarılı bir sonuç göstermiştir. Değerlendirme metriklerinin sonuçları Çizelge 4.13'te sunulmuştur. Karmaşıklık matrisi ise Şekil 4.45'te verilmiştir.

Çizelge 4.13. Sınıflandırma sonuçları

| Model                 | Doğruluk (%) | Kesinlik | Duyarlılık | F1   |
|-----------------------|--------------|----------|------------|------|
| Kolmogorov-Arnold Ağı | 93,1         | 0,95     | 0,95       | 0,95 |

|              |                       |          |                       |
|--------------|-----------------------|----------|-----------------------|
| Gerçek Sınıf | Sağlıklı              | 19       | 1                     |
|              | Hamstring Yaralanması | 1        | 8                     |
|              | Tahmin Edilen Sınıf   | Sağlıklı | Hamstring Yaralanması |

Şekil 4.45. Sınıflandırma sonucunun karmaşıklık matrisi

Sonuçlar incelendiğinde Kolmogorov-Arnold Ağı ile sınırlı veri olsa dahi hamstring kas yaralanmalarının sınıflandırılmasının mümkün olduğu gösterilmiştir.

Bu çalışmada önerilen yöntem, literatürdeki sınıflandırma ve yaralanma tespiti ile ilgili diğer çalışmalarla karşılaştırıldığında (Çizelge 4.14) başarılı sonuçlar elde etmiştir. Literatürdeki çalışmalara kıyasla bu çalışmada daha yüksek başarı oranları sağlanmıştır (Jin ve diğ., 2013; Wang ve diğ., 2021; Bardhan ve diğ., 2022; Shobayo ve diğ., 2022; Trejo-Chavez ve diğ., 2022; Ergene ve diğ., 2024; Özdil ve Yılmaz, 2024; Voinea ve diğ., 2024). Ancak, literatürdeki çalışmaların vücudun farklı bölgelerindeki çeşitli rahatsızlıkların veya yaralanmaların tespitine odaklandığı belirtilmelidir.

Çizelge 4.14. Önerilen sınıflandırma yönteminin literatürle karşılaştırılması

| Çalışma                     | Sınıflandırma Metodu           | Sınıflandırılan Bölge | Görüntüleme Tekniği | Doğruluk (%) |
|-----------------------------|--------------------------------|-----------------------|---------------------|--------------|
| Voinea ve diğ. (2024)       | ResNet                         | Ön Çapraz Bağ         | MRG                 | 97,14        |
| Jin ve diğ. (2013)          | Destek Vektör Makinaları (SVM) | Diz Osteoartriti      | Termografi          | 85,49        |
| Bardhan ve diğ. (2022)      | Destek Vektör Makinaları (SVM) | Diz Yaralanması       | Termografi          | 90,0         |
| Trejo-Chavez ve diğ. (2022) | ESA                            | Diz Yaralanması       | Termografi          | 95,09        |
| Shobayo ve diğ. (2022)      | Çok Katmanlı Perseptron        | El Bileği Kırığı      | Termografi          | 77,5         |
| Ergene ve diğ. (2024)       | EfficientnetB0                 | Hamstring Yaralanması | Termografi          | 83,9         |
| Ergene ve diğ. (2024)       | EfficientnetB1 + FPN           | Hamstring Yaralanması | Termografi          | 81,0         |
| Önerilen Metot              | Kolmogorov-Arnold Ağı          | Hamstring Yaralanması | Termografi          | 93,1         |

Futbolcuların termografik incelemesi, futbol takımları için yalnızca yaralanmaların erken tespitinde değil, aynı zamanda aktif yaralanması olan oyuncuların rehabilitasyon süreçlerinin takibinde de kritik bir rol oynamaktadır. Bu çalışmada önerilen sistem gibi yöntemler, özellikle başarı oranı göz önüne alındığında, fizyoterapistlere değerlendirme süreçlerinde önemli bir destek sağlamaktadır. Sonuç olarak, tez çalışması, profesyonel futbolcuların termografik görüntülerini kullanarak hamstring yaralanmalarının sınıflandırılması için derin öğrenmeye dayalı bir yaklaşım sunmaktadır. Daha önceki çalışmalardan farklı olarak yetersiz ve dengesiz veri setlerinden kaynaklanan zorlukları etkili bir şekilde ele alarak kapsamlı bir yaralanma tespit yaklaşımı önerilmiştir. Son olarak termografi ve Kolmogorov-Arnold Ağlarının sınıflandırma uygulamalarında bir arada kullanıldığı ilk çalışmalardan biri olarak bu araştırma, özgün bir yaklaşım sunmaktadır. Bu yenilikçi yöntem, literatüre önemli bir katkı sağlamasının yanı sıra, gelecekteki araştırmalar için ilham verici bir temel teşkil etmektedir.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1. Sonuçlar

Bu tez çalışmasında yapay zeka kullanılarak sporcu termal görüntülerinden kas bölgelerinin segmentasyonu ve yaralanmaların tespitine yönelik bir çalışmayı kapsamaktadır. Bu çalışma kapsamında üç ana konu üzerine odaklanılmıştır. Bu çalışma alanları aşağıdaki şekilde özetlenebilir;

1. Tıbbi doğrulama çalışmaları,
2. Termografik görüntülerden kas segmentasyonu,
3. Termal görüntülerde kas yaralanması sınıflandırılması.

Tıbbi doğrulama çalışmaları kapsamında termografik görüntüleme ile sporcu yaralanmalarının incelenmesi, rehabilitasyon takibi ve erken evre tespiti için kullanımına odaklanılmıştır. Termografik görüntülerden kas segmentasyonu için çeşitli derin öğrenme algoritmaları kullanılarak futbolcuların alt ekstremiteler termal görüntülerinden kas bölgelerinin segmentasyonu yapılmıştır. Termal görüntülerden yaralanma sınıflandırma çalışmalarında ise futbolcularda mevcut yaralanmaların görüntü işleme ve derin öğrenme mimarileri ile tespiti gerçekleştirilmiştir. Aynı zamanda bu çalışmalar sırasında derin öğrenmede yetersiz ve dengesiz veri seti problemine çözüm bulmak amacıyla az örnekli öğrenme üzerine de çalışılmıştır. Bu çalışmaların sonucunda çeşitli bulgular elde edilmiştir.

#### 5.1.1. Ana Bulgular

Yaralanmaların futbol takımlarına olan olumsuz etkileri detaylı olarak önceki bölümlerde verilmiştir (Bölüm 2). Futbol takımlarının yaralanmaların önüne geçmek ve rehabilitasyon takibi yaparak en etkili şekilde yaralanmaları yönetmeye çalışmaları da bu olumsuz etkilerden kaynaklanmaktadır. Bundan dolayı futbol takımları USG, MRG, BT, kan testleri, izokinetik cihazlar ve termografik görüntüleme gibi çeşitli yöntemlere başvurumaktadırlar. Kullanılan bu yöntemlerin maliyet, kullanım zorluğu ve taşıma problemi gibi dezavantajlarından dolayı termografik görüntüleme son dönemlerde etkili bir araç olarak öne çıkmaktadır. Bu çalışmada ise termal görüntüleme ile futbolcu yaralanmalarının incelenmesi üzerine çalışılmıştır. Yapılan çalışmalarda;

1. Termografik görüntüleme, futbolcu yaralanmalarının ve kas yorgunluğunun erken evrede tespit edilmesine olanak tanıyarak, yaralanmaların oluşumunun engellenmesi veya aktif yaralanmaların ilerlemesinin önlenmesini mümkün kılmaktadır.
2. Termografi, hem cerrahi müdahalelerle hem de geleneksel yöntemlerle tedavi edilen yaralanmaların rehabilitasyon süreçlerinin planlanması ve futbolcuların sahaya dönüş zamanlarının belirlenmesi için etkili bir yöntem olarak kullanılabilir.
3. Termografi, egzersizin kaslar üzerindeki etkisini izleme imkânı sunmaktadır. Bu bağlamda, aktif yaralanması bulunan futbolcularda basit bisiklet egzersizlerinin termal etkileri incelenerek yaralanma analizlerinde termografinin etkili bir yöntem olarak öne çıktığı görülmektedir. Bütün bu etkileri sayesinde termografi diğer görüntülemelere kıyasla maliyetsiz, kullanımı kolay ve kolay taşınabilir bir yöntemdir.

Bu avantajları yanında, futbol takımlarının kadro genişlikleri göz önüne alındığında bir gözlemcinin bütün futbolcuların antrenman öncesi ve sonrası görüntülerini incelemesi oldukça zaman almakta ve hata yapma ihtimalini ortaya çıkarmaktadır. Bunun için kas bölgelerinin futbolcu termal görüntülerinden segmente edilerek kasların tek tek incelenmesine olanak sağlanması fizyoterapist ve spor hekimlerine kolaylıklar sağlamaktadır. Bunun için segmentasyon üzerine yapılan çalışmalarda;

1. U-Net, PSPNet, LinkNet, FPN gibi derin öğrenme algoritmaları kullanılarak kas bölgelerinin alt ekstremitte termal görüntülerinden başarılı bir şekilde segmentasyonu mümkün hale gelmiştir.
2. Segmentasyon işlemi, kasların ayrı ayrı incelenmesine olanak tanıyarak termal görüntüleme ile inceleme yapan uzmana önemli bir kolaylık sağlamaktadır.
3. Kas bölgelerinin segmentasyonu, kas yaralanmalarının sınıflandırılmasında daha yüksek bir başarı oranı elde edilmesine katkı sunmaktadır.

Bu bulgular göz önünde bulundurulduğunda futbolcu alt ekstremitte termal görüntülerinden kas bölgelerinin segmentasyonu hem analiz yapan kişiye kolaylık

sağlamakta hem de bu segmente edilmiş kaslardan yapay zeka ve görüntü işleme metotları ile yaralanmaların sınıflandırılmasını kolaylaştırmaktadır.

Bahsedildiği üzere termografi ile yaralanmaların tespit edilmesi için bir operatöre ihtiyaç duyulması hatalar, gözden kaçan yaralanmalar ve zaman kaybına sebep olmaktadır. Bundan dolayı hataları minimize etmek ve zamandan tasarruf sağlamak için derin öğrenme algoritmaları ile termografinin beraber kullanıldığı karar destek mekanizmaları üzerine çalışılmıştır. Bunun için derin öğrenme metotları ile yaralanmaların sınıflandırılması gerçekleştirilmiştir. Yürütülen çalışmalarda;

1. Densenet, VGG, ResNet, EfficientNet, Siyam Ağları, Prototip Ağlar ve Kolmogorov-Arnold Ağı gibi derin öğrenme yöntemleri kullanılarak, termal görüntülerden kas yaralanmalarının sınıflandırılması ve tespit edilmesi mümkün hale gelmiştir.
2. Derin öğrenme modellerinde sıklıkla karşılaşılan yetersiz ve dengesiz veri setlerinin başarı oranını olumsuz etkilemesi sorununa, güncel derin öğrenme metotlarından olan Kolmogorov-Arnold Ağı ve az örnekli öğrenme yaklaşımları olan Siyam Ağları ve Prototip Ağlar kullanılarak çözüm sağlanmıştır.
3. Termografi ve derin öğrenme yöntemlerinin birlikte kullanımıyla, termal görüntülerden kasların segmentasyonu ve segmente edilen kas bölgelerindeki yaralanmaların sınıflandırılmasını içeren, baştan sona otonom bir yaralanma tespit algoritması geliştirilmiştir.

Bu tez kapsamında yapılan bu çalışmalar göz önüne alındığında termografinin futbolcu yaralanmalarının incelenmesinde başarılı bir yöntem olduğu, derin öğrenme algoritmaları ile desteklenerek yaralanmaların tespitinde diğer görüntüleme metotlarına kıyasla daha pratik, az maliyetli olduğu görülmüştür. Ayrıca rutin takip ile MRG gibi detaylı görüntüleme gerektiren durumlara karar verilmesinde faydalı olduğu görülmüştür.

### **5.1.2. Tezin Katkıları**

Bu tez, spor hekimliği, yapay zeka ve termografi alanlarında önemli katkılar sunmaktadır. Tez kapsamında yapılan çalışmalar göz önüne alındığında termografi ve derin öğrenme yöntemlerini birleştirerek futbolcu yaralanmalarının erken tespiti, rehabilitasyon süreçlerinin planlanması ve yönetilmesi için kapsamlı bir otonom sistem

geliştirilmiştir. Alt ekstremite termal görüntülerinden kasların başarılı bir şekilde segmente edilmesiyle, fizyoterapistlerin ve spor hekimlerinin kas bölgelerini ayrı ayrı incelemeleri kolaylaştırılmıştır. Segmentasyon işlemi, aynı zamanda yaralanmaların sınıflandırılmasında daha yüksek başarı oranlarının elde edilmesine katkı sağlamıştır.

Tezde, yetersiz ve dengesiz veri setlerinden kaynaklanan sorunların üstesinden gelmek amacıyla, karmaşık çok değişkenli fonksiyonları daha basit bileşenlere ayırarak, hesaplama verimliliğini arttırabilen Kolmogorov-Arnold ağları ve az örnekli öğrenme metotları olan Siyam Ağları ve Prototip Ağlar kullanılmıştır. Aynı zamanda bu yöntemler, derin öğrenme modellerinin performansını artırmış ve sınıflandırma işlemlerinin doğruluğunu sağlamıştır. Ayrıca, termografi ve derin öğrenme yöntemlerinin bütünleşik kullanımı sayesinde geliştirilen baştan sona tam otonom bir yaralanma tespit algoritması sayesinde insan operatöre duyulan ihtiyaç azaltılarak hata oranlarını en aza indirmiş ve zaman tasarrufu sağlanmıştır.

Egzersiz kaslar üzerindeki termal etkilerinin incelendiği bu tez, özellikle aktif yaralanması olan futbolcularda termografi kullanımının etkinliğini göstermiştir. Bunun yanı sıra, geliştirilen yöntem, fizyoterapistlerin ve spor hekimlerinin karar süreçlerinde etkili bir karar destek mekanizması olarak öne çıkmaktadır. Termografi ve derin öğrenme algoritmalarının bu şekilde kullanımı, futbol takımlarının yaralanma tespit süreçlerini hızlandırarak maliyetleri azaltma ve oyuncuların sahaya dönüş sürelerini kısaltma açısından stratejik bir avantaj sağlamaktadır.

Sonuç olarak, bu çalışma, termografi ve yapay zeka yöntemlerinin spor hekimliğinde etkin bir şekilde kullanılarak yaralanmaların tespitinde ve yönetiminde önemli bir katkı sunduğunu göstermektedir.

## 5.2 Öneriler

### 5.2.1. Gelecek Araştırma Önerileri

Bu tez çalışmasından elde edilen bulgular ışığında gelecekteki çalışmalar için araştırmacıların odaklanması önerilen alanlar bulunmaktadır. İlk olarak futbolcu alt ekstremite yaralanmaları üzerine daha fazla veri toplamak kullanılması planlanan segmentasyon ve sınıflandırma mimarileri için başarıyı arttıran bir kriter olarak görülmektedir. Veri sayısının yetersiz veya sınıfların dengesiz olması durumunda az örnekli öğrenme algoritmaları sınıflandırma başarısının artması için bir etken olacaktır.

Termal görüntüler ile segmentasyon ve sınıflandırma işlemleri yapılırken görüntü ile birlikte sıcaklık verilerinin de kullanılmasının faydalı olacağı öngörülmektedir. Özellik çıkarma yöntemlerinin geliştirilerek görüntülerden daha çok özellik çıkarılması veya sıcaklık verilerinden istatistiksel yaklaşımlar ile daha fazla özellik elde edilmesi yaralanma sınıflandırılması ve segmentasyon işlemleri için başarıyı arttırması potansiyeli bulunmaktadır.

Vücuttaki bütün kas bölgelerinde yaralanma tespiti için kullanılması için uygulanan metotların optimize edilmesi ve operatöre gerek kalmadan bütün yaralanmaların tespit edilmesi futbol takımları ve spor hekimleri için faydalı olacaktır. Bunun için her kas bölgesi için daha fazla veri toplanarak çalışmanın genişletilmesi önerilmektedir.

Kolmogorov-Arnold Ağı, matematiksel temelleri geçmişe dayansa da güncel problemlerin çözümünde uygulanması son yıllarda yaygınlaşmaya başlamıştır. Karmaşık fonksiyonları daha az karmaşık alt fonksiyonlara indirgeyebilmesi sayesinde Kolmogorov-Arnold Ağı hesaplama verimliliği sağlarken az veri ile de başarılı sonuçlar vermektedir. Probleme özgü olarak uyarlanması ile başarısının artması öngörülmektedir. Ayrıca yüksek sayıda veri barındıran setlerde optimizasyona ihtiyaç duymaktadır. Güncel bir metot olması ve yeniliklere açık yapısı sayesinde, önümüzdeki yıllarda Kolmogorov-Arnold Ağı üzerine yapılan çalışmaların artacağı öngörülmektedir. Bu doğrultuda, Kolmogorov-Arnold Ağının probleme özgü çalışmalar ve modern optimizasyon teknikleri ile geliştirilmesi önerilmektedir.

### 5.2.2. Çalışmanın Uygulama Alanları

Bu çalışmada geliştirilen termografi ve derin öğrenme yöntemlerini birleştiren yaralanma tespit algoritması, spor hekimliği ve profesyonel futbol dünyasında geniş uygulama alanlarına sahiptir. Geliştirilen bu sistem, futbol takımları ve sporcular için yalnızca yaralanma tespiti değil, aynı zamanda antrenman yükünün düzenlenmesi ve rehabilitasyon süreçlerinin daha etkili bir şekilde yönetilmesi için kullanılabilir. Bu çalışmanın pratik uygulama alanları şunları içerebilir;

1. Yaralanma Tespiti ve Erken Müdahale: Çalışmanın sunduğu yöntem, futbolcuların alt ekstremitte kaslarındaki yaralanmaların erken evrede tespit edilmesine olanak sağlamaktadır. Erken teşhis, yaralanmaların ilerlemesinin önlenmesini ve tedavi süreçlerinin daha hızlı bir şekilde

başlamasını ön ayak olmaktadır. Bu durum, oyuncuların antrenmanlardan ve maçlardan uzak kalma sürelerini önemli ölçüde kısaltabilir.

2. Rehabilitasyon Süreçlerinin Planlanması: Geliştirilen algoritma, yaralanmaların termal görüntüler üzerinden izlenmesine imkân tanıyarak rehabilitasyon sürecinin etkili bir şekilde planlanmasına olanak tanımaktadır. Bu sistem, rehabilitasyonun ilerleyişini objektif bir şekilde ölçerek tedavi planlarının optimize edilmesine yardımcı olmaktadır. Böylelikle oyuncuların sahaya dönüş süreleri en verimli şekilde yönetilebilir.
3. Performans İzleme ve Önleyici Tedbirler: Egzersiz sonrası kasların termal analizinin yapılması, sporcuların kaslarındaki aşırı yüklenme veya yorgunluk belirtilerini erken dönemde tespit edebilmektedir. Bu yöntem, antrenman programlarının kişiselleştirilmesine ve yaralanma risklerinin azaltılmasına yönelik önleyici tedbirlerin alınmasına olanak sağlamaktadır.
4. Futbol Takımları İçin Karar Destek Mekanizması: Geliştirilen sistem, fizyoterapistler ve spor hekimleri için hızlı ve güvenilir bir karar destek mekanizması sunmaktadır. Özellikle yoğun maç ve antrenman programlarında oyuncuların termal görüntülerinin hızlı bir şekilde analiz edilmesi, yaralanma yönetimi sürecinde önemli bir avantaj sağlamaktadır.
5. Diğer Spor Branşlarında Kullanım: Bu çalışmada geliştirilen metodolojinin, yalnızca futbol değil, basketbol, voleybol ve atletizm gibi diğer spor dallarında da uygulanabilir olması mümkündür. Her spor dalında meydana gelen spesifik yaralanmalar için uygun şekilde optimize edilerek genişletilebilir.
6. Sporcu Sağlığı ve Genel Kullanım: Profesyonel sporcular dışında, amatör sporcuların ve genel toplumun kas ve iskelet sistemi sağlığının izlenmesinde de bu yöntem kullanılabilir. Örneğin, spor salonlarında veya bireysel rehabilitasyon programlarında uygulanabilecek taşınabilir ve düşük maliyetli bir çözümler üretilebilir.

Sonuç olarak, bu tez kapsamında sunulan yöntemler, spor hekimliği ve termografi alanında önemli katkılar sunma potansiyeline sahiptir. Hem profesyonel spor kulüplerinde hem de bireysel sağlık izleme sistemlerinde yaygın olarak kullanılabilir.

Bu durum, sporcu sađlıđına y6nelik tedavi ve 6nleme stratejilerinin daha etkili hale gelmesini sađlayarak, yaralanmaların mali ve fiziksel etkilerini en aza indirmeyi hedeflemektedir.



## KAYNAKLAR

- Alvurdu, S., Arslan, Y., Keskin, K., Oliveira, R. ve Nobari, H., 2024, Acute skin temperature responses to the 30-15 intermittent fitness test in professional male soccer players. <https://doi.org/10.21203/rs.3.rs-4730730/v1>
- Andrés López, D., Hillen, B., Nägele, M., Simon, P. ve Schömer, E., 2024, ThermoNet: advanced deep neural network-based thermogram processing pipeline for automatic time series analysis of specific skin areas in moving legs, *Journal of Thermal Analysis and Calorimetry*, 1-12. <https://doi.org/10.1007/s10973-024-13625-3>
- Arıncı, K. ve Elhan, A., 2020, *Anatomi*, İstanbul: Güneş Yayınevi, p. 206.
- Arnold, V. I., 2009, On functions of three variables, *Collected Works: Representations of Functions, Celestial Mechanics and KAM Theory, 1957–1965*, 5-8. [https://doi.org/10.1007/978-3-642-01742-1\\_2](https://doi.org/10.1007/978-3-642-01742-1_2)
- Baker, B. E., Peckham, A. C., Puppato, F. ve Sanborn, J. C., 1985, Review of meniscal injury and associated sports, *The American journal of sports medicine*, 13 (1), 1-4. <https://doi.org/10.1177/036354658501300101>
- Bardhan, S., Nath, S., Debnath, T., Bhattacharjee, D. ve Bhowmik, M. K., 2022, Designing of an inflammatory knee joint thermogram dataset for arthritis classification using deep convolution neural network, *Quantitative InfraRed Thermography Journal*, 19 (3), 145-171. <https://doi.org/10.1080/17686733.2020.1855390>
- Bayrak, A., Ergene, M. C. ve Ceylan, M., 2021a, Assessment of The Athlete with a History of Proximal Rectus Femoris Tendon Rupture Injury Treated Operatively by Thermography Under the Effect of Training. Uluslararası Gazi Sağlık Bilimleri Kongresi: 300-312.
- Bayrak, A., Ergene, M. C. ve Ceylan, M., 2021b, Futbolda Menisküs Yaralanmalarının Taranmasında Ön Değerlendirme Aracı Olarak Termografi Kullanımı: Olgu Sunumu. III. International Congress of Athletic Performance & Health in Sports. International Journal of Sport Exercise and Training Sciences. 5: 106-108.
- Bayrak, A., Ergene, M. C. ve Ceylan, M., 2021c, The Process of Returning to Sports with Infrared Thermography (IRT) After a Rectus Femoris Proximal Tear in an Elite Football Player. International Congress of Sports Medicine 18th Turkish Sports Medicine Congress. Online: 85-91.
- Bayrak, A., Ergene, M. C. ve Ceylan, M., 2023, Monitoring The Reactions of Athletes With History of Rectus Femoris Proximal Tear Healed With Different Methods to Training Load With Thermography, *Turkish Journal of Sport and Exercise*, 25 (2), 231-239. <https://doi.org/10.15314/tsed.1292549>
- Bayrak, A., Ergene, M. C. ve Ceylan, M., 2024, Thermography method under the influence of exercise in the detection of muscle injuries: Sartorius muscle case report, *Journal of Bodywork and Movement Therapies*, 39, 109-115. <https://doi.org/10.1016/j.jbmt.2024.02.029>
- Bougrine, A., Harba, R., Canals, R., Ledee, R. ve Jabloun, M., 2019, On the segmentation of plantar foot thermal images with Deep Learning, *2019 27th European Signal Processing Conference (EUSIPCO)*, 1-5. <https://doi.org/10.23919/EUSIPCO.2019.8902691>

- Brancaccio, P., Maffulli, N. ve Limongelli, F. M., 2007, Creatine kinase monitoring in sport medicine, *British medical bulletin*, 81 (1), 209-230. <https://doi.org/10.1093/bmb/ldm014>
- Brandser, E. A., El-Khoury, G. Y., Kathol, M. H., Callaghan, J. J. ve Tearse, D. S., 1995, Hamstring injuries: radiographic, conventional tomographic, CT, and MR imaging characteristics, *Radiology*, 197 (1), 257-262. <https://doi.org/10.1148/radiology.197.1.7568833>
- Bromley, J., Guyon, I., LeCun, Y., Säcker, E. ve Shah, R., 1993, Signature verification using a "siamese" time delay neural network, *Advances in neural information processing systems*, 6. <https://doi.org/10.1142/S0218001493000339>
- Cabaniss, C. D., 1990, Creatine kinase, *Clinical Methods: The History, Physical, and Laboratory Examinations*. 3rd edition.
- Carreras, M. ve Garcia, J., 2018, TV rights, financial inequality, and competitive balance in European football: Evidence from the English Premier League and the Spanish LaLiga, *International Journal of Sport Finance*, 13 (3), 201-224.
- Chang, V., Sajeev, S., Xu, Q. A., Tan, M. ve Wang, H., 2024, Football Analytics: Assessing the Correlation between Workload, Injury and Performance of Football Players in the English Premier League, *Applied Sciences*, 14 (16), 7217. <https://doi.org/10.3390/app14167217>
- Chaurasia, A. ve Culurciello, E., 2017, Linknet: Exploiting encoder representations for efficient semantic segmentation, *2017 IEEE visual communications and image processing (VCIP)*, 1-4. <https://doi.org/10.1109/VCIP.2017.8305148>
- Côrte, A. C., Pedrinelli, A., Martos, A., Souza, I. F. G., Grava, J. ve Hernandez, A. J., 2019, Infrared thermography study as a complementary method of screening and prevention of muscle injuries: pilot study, *BMJ Open Sport & Exercise Medicine*, 5 (1), e000431. <https://doi.org/10.1136/bmjsem-2018-000431>
- Crema, M. D., Guermazi, A., Tol, J. L., Niu, J., Hamilton, B. ve Roemer, F. W., 2016, Acute hamstring injury in football players: association between anatomical location and extent of injury—a large single-center MRI report, *Journal of science and medicine in sport*, 19 (4), 317-322. <https://doi.org/10.1016/j.jsams.2015.04.005>
- Crema, M. D., Yamada, A. F., Guermazi, A., Roemer, F. W. ve Skaf, A. Y., 2015, Imaging techniques for muscle injury in sports medicine and clinical relevance, *Current reviews in musculoskeletal medicine*, 8, 154-161. <https://doi.org/10.1007/s12178-015-9260-4>
- da Silva, M. E. A., da Silva, T. C. V. ve dos Santos, W. P., 2024, Infrared Thermography: Principles and Applications in Healthcare, *Biomedical Imaging: Principles and Advancements*, 40.
- de Andrade Fernandes, A., Marins, J. C. B., de Andrade, A. G. P., Albuquerque, M. R., Brito, C. J., da Silva, C. D., do Valle, M. A. A. N., de Assis, M. G., Garcia, E. S. ve Pimenta, E. M., 2024, Thermopixelgraphy: a new method for analyzing the skin temperature of the lower limbs through infrared thermography, *Journal of Thermal Analysis and Calorimetry*, 1-9. <https://doi.org/10.1007/s10973-024-13799-w>
- de Rezende, C. M., da Silva, A. G., Sillero-Quintana, M. ve Marins, J. C. B., 2024, Patterns of thermal normality of the knee joint in professional athletes of different sports, *Journal of Thermal Biology*, 103991. <https://doi.org/10.1016/j.jtherbio.2024.103991>
- Deoli, P., Kumar, R., Vierling, A. ve Berns, K., 2024, Evaluating the Robustness of Off-Road Autonomous Driving Segmentation against Adversarial Attacks: A

- Dataset-Centric analysis, *arXiv preprint arXiv:2402.02154*.  
<https://doi.org/10.48550/arXiv.2402.02154>
- Dong, K., Zhou, C., Ruan, Y. ve Li, Y., 2020, MobileNetV2 model for image classification, *2020 2nd International Conference on Information Technology and Computer Application (ITCA)*, 476-480.  
<https://doi.org/10.1109/ITCA52113.2020.00106>
- dos Santos Bunn, P., Miranda, M. E. K., Rodrigues, A. I., de Souza Sodré, R., Neves, E. B. ve da Silva, E. B., 2020, Infrared thermography and musculoskeletal injuries: a systematic review with meta-analysis, *Infrared Physics & Technology*, 109, 103435. <https://doi.org/10.1016/j.infrared.2020.103435>
- Du, G., Cao, X., Liang, J., Chen, X. ve Zhan, Y., 2020, Medical Image Segmentation based on U-Net: A Review, *Journal of Imaging Science & Technology*, 64 (2).  
<https://doi.org/10.2352/J.ImagingSci.Technol.2020.64.2.020508>
- Durmuş, M., Ergen, B., Çelebi, A. ve Türkoğlu, M., 2024, ResNet Tabanlı PSPNet Kullanarak Panoramik Görüntülerde Gömülü Dış Segmentasyon Analizi, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 36 (1), 159-166.  
<https://doi.org/10.35234/fumbd.1404979>
- Dziedzic, D., Bogacka, U. ve Ciszek, B., 2014, Anatomy of sartorius muscle, *Folia morphologica*, 73 (3), 359-362. <https://doi.org/10.5603/FM.2014.0037>
- Eliakim, E., Morgulev, E., Lidor, R. ve Meckel, Y., 2020, Estimation of injury costs: financial damage of English Premier League teams' underachievement due to injuries, *BMJ Open Sport & Exercise Medicine*, 6 (1), e000675.  
<https://doi.org/10.1136/bmjsem-2019-000675>
- Ergene, M. C., Bayrak, A. ve Ceylan, M., 2020, Tracking the injury recovery of professional football players with infrared thermography: Preliminary Study, *Avrupa Bilim ve Teknoloji Dergisi*, 207-213.  
<https://doi.org/10.31590/ejosat.804151>
- Ergene, M. C., Bayrak, A. ve Ceylan, M., 2024, A new deep learning based end-to-end pipeline for hamstring injury detection in thermal images of professional football player, *Quantitative InfraRed Thermography Journal*, 1-18.  
<https://doi.org/10.1080/17686733.2024.2364964>
- Ergene, M. C., Bayrak, A., Çevik, M. ve Ceylan, M., 2023, Evaluation of deep learning models for lower extremity muscle segmentation in thermal imaging, *MICCAI Workshop on Artificial Intelligence over Infrared Images for Medical Applications*, 109-120. [https://doi.org/10.1007/978-3-031-44511-8\\_9](https://doi.org/10.1007/978-3-031-44511-8_9)
- Escamilla-Galindo, V.-L., Felipe, J. L., Alonso-Callejo, A., Van-der-Horst, R., de la Torre-Combarros, A., Minafra, P., Fernández-Muñoz, D. ve Fernández-Cuevas, I., 2025, Return-to-play criteria based on infrared thermography during anterior cruciate ligament rehabilitation in football players, *Biology of Sport*, 42 (2), 161-167. <https://doi.org/10.5114/biolsport.2025.144295>
- Esser, S., Jantz, D., Hurdle, M. F. ve Taylor, W., 2015, Proximal rectus femoris avulsion: ultrasonic diagnosis and nonoperative management, *Journal of athletic training*, 50 (7), 778-780. <https://doi.org/10.4085/1052-6050-50.2.13>
- Everett, G., Beal, R., Matthews, T., Norman, T. J. ve Ramchurn, S. D., 2024, The Strain of Success: A Predictive Model for Injury Risk Mitigation and Team Success in Soccer, *arXiv preprint arXiv:2402.04898*.  
<https://doi.org/10.48550/arXiv.2402.04898>
- Fadhil, B. A., Sarhan, S. A. ve Muhammed, M., 2024, The effect of (HIPT) exercises on developing the endurance rate, strength endurance, and skill performance of youth in football, *Misan Journal for Physical Education Sciences* (1).

- Falk, T., Mai, D., Bensch, R., Çiçek, Ö., Abdulkadir, A., Marrakchi, Y., Böhm, A., Deubner, J., Jäckel, Z. ve Seiwald, K., 2019, U-Net: deep learning for cell counting, detection, and morphometry, *Nature methods*, 16 (1), 67-70. <https://doi.org/10.1038/s41592-018-0261-2>
- Fornage, B. D., Touche, D. H., Segal, P. ve Rifkin, M., 1983, Ultrasonography in the evaluation of muscular trauma, *Journal of Ultrasound in Medicine*, 2 (12), 549-554. <https://doi.org/10.7863/jum.1983.2.12.549>
- Forsythe, B., Knapik, D. M., Crawford, M. D., Diaz, C. C., Hardin, D., Gallucci, J., Silvers-Granelli, H. J., Mandelbaum, B. R., Lemak, L. ve Putukian, M., 2022, Incidence of injury for professional soccer players in the United States: A 6-year prospective study of Major League Soccer, *Orthopaedic journal of sports medicine*, 10 (3), 23259671211055136. <https://doi.org/10.1177/2325967121105513>
- Gaines, J. M. ve Talbot, L. A., 1999, Isokinetic strength testing in research and practice, *Biological research for nursing*, 1 (1), 57-64. <https://doi.org/10.1177/109980049900100108>
- Gamradt, S. C., Brophy, R. H., Barnes, R., Warren, R. F., Byrd, J. T. ve Kelly, B. T., 2009, Nonoperative treatment for proximal avulsion of the rectus femoris in professional American football, *The American journal of sports medicine*, 37 (7), 1370-1374. <https://doi.org/10.1177/0363546509333477>
- Garcia-Unanue, J., Hernandez-Martin, A., Viejo-Romero, D., Manzano-Carrasco, S., Sanchez-Sanchez, J., Gallardo, L. ve Felipe, J. L., 2024, The Impact of a Congested Match Schedule (Due to the COVID-19 Lockdown) on Creatine Kinase (CK) in Elite Football Players Using GPS Tracking Technology, *Sensors*, 24 (21), 6917. <https://doi.org/doi.org/10.3390/s24216917>
- Gaussorgues, G. ve Chomet, S., 2012, Infrared thermography, Springer Science & Business Media, p.
- Gee, S. M., Tennent, D. J., Cameron, K. L. ve Posner, M. A., 2020, The burden of meniscus injury in young and physically active populations, *Clinics in sports medicine*, 39 (1), 13-27. <https://doi.org/10.1016/j.csm.2019.08.008>
- Gomez-Carmona, P., Fernández-Cuevas, I., Sillero-Quintana, M., Arnaiz-Lastras, J. ve Navandar, A., 2020, Infrared thermography protocol on reducing the incidence of soccer injuries, *Journal of sport rehabilitation*, 29 (8), 1222-1227. <https://doi.org/10.1123/jsr.2019-0056>
- Hakim, A. S. ve Awale, R., 2022, Extraction of hottest blood vessels from breast thermograms using state-of-the-art image segmentation methods, *Quantitative InfraRed Thermography Journal*, 19 (5), 347-365. <https://doi.org/10.1080/17686733.2021.1974209>
- Hasselmann, C. T., Best, T. M., Hughes IV, C., Martinez, S. ve Garrett Jr, W. E., 1995, An explanation for various rectus femoris strain injuries using previously undescribed muscle architecture, *The American journal of sports medicine*, 23 (4), 493-499. <https://doi.org/10.1177/036354659502300421>
- Hawkins, R. D., Hulse, M., Wilkinson, C., Hodson, A. ve Gibson, M., 2001, The association football medical research programme: an audit of injuries in professional football, *British journal of sports medicine*, 35 (1), 43-47. <https://doi.org/10.1136/bjsm.35.1.43>
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778. <https://doi.org/10.48550/arXiv.1512.03385>

- Hildebrandt, C., Raschner, C. ve Ammer, K., 2010, An overview of recent application of medical infrared thermography in sports medicine in Austria, *Sensors*, 10 (5), 4700-4715. <https://doi.org/10.3390/s100504700>
- Hix, B., Moreira, M., Leite, J. P. ve de Meneck, F., 2024, Leveraging AI in Infrared Medical Imaging: Supporting the early diagnosis of illness, injury, or infection, *The Journal of Business and Artificial Intelligence*, 1 (1), 12-12.
- Hou, Y. ve Zhang, D., 2024, A comprehensive survey on kolmogorov arnold networks (kan), *arXiv preprint arXiv:2407.11075*. <https://doi.org/10.48550/arXiv.2407.11075>
- Hsieh, J. ve Flohr, T., 2021, Computed tomography recent history and future perspectives, *Journal of Medical Imaging*, 8 (5), 052109-052109. <https://doi.org/10.1117/1.JMI.8.5.052109>
- Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q., 2017, Densely connected convolutional networks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708. <https://doi.org/10.48550/arXiv.1608.06993>
- Hughes IV, C., Hasselman, C. T., Best, T. M., Martinez, S. ve Garrett Jr, W. E., 1995, Incomplete, intrasubstance strain injuries of the rectus femoris muscle, *The American journal of sports medicine*, 23 (4), 500-506. <https://doi.org/10.1177/03635465950230042>
- Isern-Kebschull, J., Mechó, S., Pruna, R., Kassarian, A., Valle, X., Yanguas, X., Alomar, X., Martinez, J., Pomés, J. ve Rodas, G., 2020, Sports-related lower limb muscle injuries: pattern recognition approach and MRI review, *Insights into imaging*, 11 (1), 108. <https://doi.org/10.1186/s13244-020-00912-4>
- Jacobson, J. A. ve van Holsbeeck, M. T., 1998, Musculoskeletal ultrasonography, *Orthopedic Clinics*, 29 (1), 135-167. [https://doi.org/10.1016/S0030-5898\(05\)70010-9](https://doi.org/10.1016/S0030-5898(05)70010-9)
- Jamali, A., Roy, S. K., Hong, D., Lu, B. ve Ghamisi, P., 2024, How to Learn More? Exploring Kolmogorov–Arnold Networks for Hyperspectral Image Classification, *Remote Sensing*, 16 (21), 4015. <https://doi.org/10.3390/rs16214015>
- Jiang, Z., Hao, Y., Jin, N. ve Li, Y., 2022, A systematic review of the relationship between workload and injury risk of professional male soccer players, *International Journal of Environmental Research and Public Health*, 19 (20), 13237. <https://doi.org/10.3390/ijerph192013237>
- Jin, C., Yang, Y., Xue, Z.-J., Liu, K.-M. ve Liu, J., 2013, Automated analysis method for screening knee osteoarthritis using medical infrared thermography, *Journal of Medical and Biological Engineering*, 33 (5), 471-477. <https://doi.org/10.5405/jmbe.1054>
- Kim, S.-W., Kook, H.-K., Sun, J.-Y., Kang, M.-C. ve Ko, S.-J., 2018, Parallel feature pyramid network for object detection, *Proceedings of the European conference on computer vision (ECCV)*, 234-250. [https://doi.org/10.1007/978-3-030-01228-1\\_15](https://doi.org/10.1007/978-3-030-01228-1_15)
- Koch, G., Zemel, R. ve Salakhutdinov, R., 2015, Siamese neural networks for one-shot image recognition, *ICML deep learning workshop*, 1-30.
- Koonce, B., 2021, Convolutional neural networks with swift for tensorflow: Image recognition and dataset categorization, Springer, p. <https://doi.org/10.1007/978-1-4842-6168-2>
- Kuperman, V., 2000, Magnetic resonance imaging: physical principles and applications, Elsevier, p.

- Kůrková, V., 1992, Kolmogorov's theorem and multilayer neural networks, *Neural networks*, 5 (3), 501-506. [https://doi.org/10.1016/0893-6080\(92\)90012-8](https://doi.org/10.1016/0893-6080(92)90012-8)
- Langley, S. P., 1880, The bolometer and radiant energy, *Proceedings of the American Academy of Arts and Sciences*, 342-358. <https://doi.org/10.2307/25138616>
- Lawson, R., 1956, Implications of surface temperatures in the diagnosis of breast cancer, *Canadian Medical Association Journal*, 75 (4), 309.
- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B. ve Belongie, S., 2017, Feature pyramid networks for object detection, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2117-2125. <https://doi.org/10.48550/arXiv.1612.03144>
- Liu, W. ve Zeng, K., 2018, SparseNet: A sparse DenseNet for image classification, *arXiv preprint arXiv:1804.05340*. <https://doi.org/10.48550/arXiv.1804.05340>
- Liu, Z., Wang, Y., Vaidya, S., Ruehle, F., Halverson, J., Soljačić, M., Hou, T. Y. ve Tegmark, M., 2024, Kan: Kolmogorov-arnold networks, *arXiv preprint arXiv:2404.19756*. <https://doi.org/10.48550/arXiv.2404.19756>
- Lozano III, A. ve Hassanipour, F., 2019, Infrared imaging for breast cancer detection: An objective review of foundational studies and its proper role in breast cancer screening, *Infrared Physics & Technology*, 97, 244-257. <https://doi.org/10.1016/j.infrared.2018.12.017>
- Lu, D., McCall, A., Jones, M., Steinweg, J., Gelis, L., Fransen, J. ve Duffield, R., 2021, The financial and performance cost of injuries to teams in Australian professional soccer, *Journal of science and medicine in sport*, 24 (5), 463-467. <https://doi.org/10.1016/j.jsams.2020.11.004>
- Lucas, V. S., Burk, R. S., Creehan, S. ve Grap, M. J., 2014, Utility of high-frequency ultrasound: moving beyond the surface to detect changes in skin integrity, *Plastic and Aesthetic Nursing*, 34 (1), 34-38. <https://doi.org/10.1097/PSN.0000000000000031>
- Lucchi, E., 2018, Applications of the infrared thermography in the energy audit of buildings: A review, *Renewable and Sustainable Energy Reviews*, 82, 3077-3090. <https://doi.org/10.1016/j.rser.2017.10.031>
- Ludvigsen, J. A. L., 2022, Football and risk: Trends and perspectives, Routledge, p. <https://doi.org/10.4324/9781003303480>
- Majano, C., García-Unanue, J., Fernández-Cuevas, I., Escamilla-Galindo, V., Alonso-Callejo, A., Gallardo, L. ve Felipe, J. L., 2024, Assessment of the acclimatization influence on thermography patterns in youth football players: a pilot study, *Journal of Thermal Analysis and Calorimetry*, 149 (17), 9343-9352. <https://doi.org/10.1007/s10973-024-13432-w>
- Malherbe, K., 2019, A rare ultrasound case report: intramuscular tear of the sartorius muscle, *The Ultrasound Journal*, 11 (1), 17. <https://doi.org/10.1186/s13089-019-0132-9>
- Marshall, C. H., 1976, Principles of computed tomography, *Postgraduate Medicine*, 60 (2), 105-109. <https://doi.org/10.1080/00325481.1976.11708381>
- Martínez Serrano, A., 2024, Fatigue monitoring and mechanical properties of the hamstring muscles in football players.
- McKenna, J., 2024, The Cost of Injuries in the Premier League: 2023/2024, <https://analyticsfc.co.uk/blog/2024/07/18/the-cost-of-injuries-in-the-premier-league-2023-2024/>: [18 Kasım 2024].
- McNeely-White, D., Beveridge, J. R. ve Draper, B. A., 2020, Inception and ResNet features are (almost) equivalent, *Cognitive Systems Research*, 59, 312-318. <https://doi.org/10.1016/j.cogsys.2019.10.004>

- Mendiguchia, J., Alentorn-Geli, E., Idoate, F. ve Myer, G. D., 2013, Rectus femoris muscle injuries in football: a clinically relevant review of mechanisms of injury, risk factors and preventive strategies, *British journal of sports medicine*, 47 (6), 359-366. <https://doi.org/10.1136/bjsports-2012-091250>
- Mendis, M. D. ve Hides, J. A., 2016, Effect of motor control training on hip muscles in elite football players with and without low back pain, *Journal of science and medicine in sport*, 19 (11), 866-871. <https://doi.org/10.1016/j.jsams.2016.02.008>
- Meola, C., 2012, Infrared thermography recent advances and future trends.
- Miller, M. D., Thompson, S. R. ve Hart, J., 2012, Review of orthopaedics, Elsevier Health Sciences, p.
- Mirenayat, M. S., Faramarzi, M., Ghazvini, M. R., Karimian, J., Hadi, A., Heidari, Z., Rouhani, M. H. ve Naeini, A. A., 2024, The effects of short term citrulline malate supplementation on oxidative stress and muscle damage in trained soccer players, *Human Nutrition & Metabolism*, 36, 200242. <https://doi.org/10.1016/j.hnm.2024.200242>
- Moffroid, M., Whipple, R., Hofkosh, J., Lowman, E. ve Thistle, H., 1969, A study of isokinetic exercise, *Physical Therapy*, 49 (7), 735-747. <https://doi.org/10.1177/1099800499001001>
- Mohd Ali, N., Md Rashid, N. K. A. ve Mustafah, Y. M., 2013, Performance comparison between RGB and HSV color segmentations for road signs detection, *Applied Mechanics and Materials*, 393, 550-555. <https://doi.org/10.4028/www.scientific.net/AMM.393.550>
- Moore, K. L., Agur, A. M., Dalley, A. F. ve Moore, K. L., 2015, Essential clinical anatomy, p. 433-434.
- Mummaneni, S., Ravi, S. T., Bodedla, J., Vemulapalli, S. R. ve Jagathapurao, G. S. K. V., 2024, A COMPREHENSIVE STUDY: INTRACRANIAL ANEURYSM DETECTION VIA VGG16-DENSENET HYBRID DEEP LEARNING ON DSA IMAGES, *Informatyka, Automatyka, Pomiar w Gospodarce i Ochronie Środowiska*, 14 (1), 105-110. <https://doi.org/10.35784/iapgos.5804>
- Nandhitha, N., Emalda Roslin, S., Chakravarthi, R. ve Sangeetha, M., 2021, Feasibility of Infrared Thermography for Health Monitoring of Archeological Structures, In: Smart Intelligent Computing and Communication Technology, Eds: IOS Press, p. 111-117. <https://doi.org/10.3233/APC210021>
- Netter, F. H. ve Hansen, J. T., 2018, Netter's clinical anatomy, Elsevier, p.
- Ng, K. H., 2003, Non-ionizing radiations—sources, biological effects, emissions and exposures, *Proceedings of the International Conference on Non-Ionizing Radiation at UNITEN*.
- Nieto Torrejón, L., Martínez-Serrano, A., Villalón, J. M. ve Alcaraz, P. E., 2024, Economic impact of muscle injury rate and hamstring strain injuries in professional football clubs. Evidence from LaLiga, *Plos one*, 19 (6), e0301498. <https://doi.org/10.1371/journal.pone.0301498>
- Olson, D. L. ve Delen, D., 2008, Advanced data mining techniques, Springer Science & Business Media, p. <https://doi.org/10.1007/978-3-540-76917-0>
- Özdil, A. ve Yilmaz, B., 2024, Medical infrared thermal image based fatty liver classification using machine and deep learning, *Quantitative InfraRed Thermography Journal*, 21 (2), 102-119. <https://doi.org/10.1080/17686733.2022.2158678>
- Özdil, A. ve Yilmaz, B., 2022, Automatic body part and pose detection in medical infrared thermal images, *Quantitative InfraRed Thermography Journal*, 19 (4), 223-238. <https://doi.org/10.1080/17686733.2021.1947595>

- Peetrons, P., 2002, Ultrasound of muscles, *European radiology*, 12 (1), 35-43. <https://doi.org/10.1007/s00330-001-1164-6>
- Perpetuini, D., Formenti, D., Cardone, D., Trecroci, A., Rossi, A., Di Credico, A., Merati, G., Alberti, G., Di Baldassarre, A. ve Merla, A., 2023, Can data-driven supervised machine learning approaches applied to infrared thermal imaging data estimate muscular activity and fatigue?, *Sensors*, 23 (2), 832. <https://doi.org/10.3390/s23020832>
- Petersen, J., Thorborg, K., Nielsen, M. B., Skjødt, T., Bolvig, L., Bang, N. ve Hölmich, P., 2014, The diagnostic and prognostic value of ultrasonography in soccer players with acute hamstring injuries, *The American journal of sports medicine*, 42 (2), 399-404. <https://doi.org/10.1177/036354651351277>
- Petrigna, L., Amato, A., Roggio, F., Trovato, B. ve Musumeci, G., 2024, Thermal threshold for knee osteoarthritis people evaluated with infrared thermography: A scoping review, *Journal of Thermal Biology*, 103932. <https://doi.org/10.1016/j.jtherbio.2024.103932>
- Pillitteri, G., Clemente, F. M., Sarmiento, H., Figueredo, A., Rossi, A., Bongiovanni, T., Puleo, G., Petrucci, M., Foster, C. ve Battaglia, G., 2024, Translating player monitoring into training prescriptions: Real world soccer scenario and practical proposals, *International Journal of Sports Science & Coaching*, 17479541241289080. <https://doi.org/10.1177/17479541241289080>
- Ptasznik, R., 1999, Ultrasound in acute and chronic knee injury, *Radiologic Clinics of North America*, 37 (4), 797-830. [https://doi.org/10.1016/S0033-8389\(05\)70130-5](https://doi.org/10.1016/S0033-8389(05)70130-5)
- Quesada, J. I. P., 2017, Application of infrared thermography in sports science, Springer, p. <https://doi.org/10.1007/978-3-319-47410-6>
- Rakhunde, M. B., Gotarkar, S. ve Choudhari, S. G., 2022, Thermography as a breast cancer screening technique: a review article, *Cureus*, 14 (11). <https://doi.org/10.7759/cureus.31251>
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *Medical image computing and computer-assisted intervention–MICCAI 2015: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III* 18, 234-241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Rosengarten, S. D., Cook, J. L., Bryant, A. L., Cordy, J. T., Daffy, J. ve Docking, S. I., 2015, Australian football players' Achilles tendons respond to game loads within 2 days: an ultrasound tissue characterisation (UTC) study, *British journal of sports medicine*, 49 (3), 183-187. <https://doi.org/10.1136/bjsports-2013-092713>
- Rubin, E. B., Schmidt, A. M., Koff, M. F., Kogan, F., Gao, K., Majumdar, S., Potter, H. ve Gold, G. E., 2024, Advanced MRI Approaches for Evaluating Common Lower Extremity Injuries in Basketball Players: Current and Emerging Techniques, *Journal of Magnetic Resonance Imaging*, 59 (6), 1902-1913. <https://doi.org/10.1002/jmri.29019>
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., Huang, Z., Karpathy, A., Khosla, A. ve Bernstein, M., 2015, Imagenet large scale visual recognition challenge, *International journal of computer vision*, 115, 211-252. <https://doi.org/10.48550/arXiv.1409.0575>
- Schuster, N. ve Kolobrodov, V. G., 2004, Infrarotthermographie, John Wiley & Sons, p.
- Seferbekov, S., Iglovikov, V., Buslaev, A. ve Shvets, A., 2018, Feature pyramid network for multi-class land segmentation, *Proceedings of the IEEE conference*

- on computer vision and pattern recognition workshops, 272-275. <https://doi.org/10.1109/CVPRW.2018.00051>
- Shannon, C. E., 1948, A mathematical theory of communication, *The Bell system technical journal*, 27 (3), 379-423. <https://doi.org/10.1002/j.1538-7305.1948.tb01338.x>
- Shelly, M. J., Hodnett, P. A., MacMahon, P. J., Moynagh, M. R., Kavanagh, E. C. ve Eustace, S. J., 2009, MR imaging of muscle injury, *Magnetic Resonance Imaging Clinics*, 17 (4), 757-773. <https://doi.org/10.1016/j.mric.2009.06.012>
- Shobayo, O., Saatchi, R. ve Ramlakhan, S., 2022, Infrared thermal imaging and artificial neural networks to screen for wrist fractures in pediatrics, *Technologies*, 10 (6), 119. <https://doi.org/10.3390/technologies10060119>
- Sillero-Quintana, M., Gomez-Carmona, P. M. ve Fernández-Cuevas, I., 2021, Infrared thermography as a means of monitoring and preventing sports injuries, In: *Research Anthology on Business Strategies, Health Factors, and Ethical Implications in Sports and eSports*, Eds: IGI Global, p. 832-865. <https://doi.org/10.4018/978-1-7998-7707-3.ch046>
- Simonyan, K., 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint arXiv:1409.1556*. <https://doi.org/10.48550/arXiv.1409.1556>
- Sipilä, S. ve Suominen, H., 1993, Muscle ultrasonography and computed tomography in elderly trained and untrained women, *Muscle & Nerve: Official Journal of the American Association of Electrodiagnostic Medicine*, 16 (3), 294-300. <https://doi.org/10.1002/mus.880160309>
- Smigaj, M., Agarwal, A., Bartholomeus, H., Decuyper, M., Elsherif, A., de Jonge, A. ve Kooistra, L., 2024, Thermal infrared remote sensing of stress responses in forest environments: a review of developments, Challenges, and Opportunities, *Current Forestry Reports*, 10 (1), 56-76. <https://doi.org/10.1007/s40725-023-00207-z>
- Snell, J., Swersky, K. ve Zemel, R., 2017, Prototypical networks for few-shot learning, *Advances in neural information processing systems*, 30. <https://doi.org/10.48550/arXiv.1703.05175>
- Snell, R. S., 2000, *Clinical anatomy for medical students*, Lippincott Williams & Wilkins, p.
- Sobotta, J., 2005, *Sobotta atlas of human anatomy II*, Elsevier, p.
- Speer, K. P., Lohnes, J. ve Garrett JR, W. E., 1993, Radiographic imaging of muscle strain injury, *The American journal of sports medicine*, 21 (1), 89-96. <https://doi.org/10.1177/03635465930210011>
- Sudha, B., Umadevi, V. ve Shivaram, J. M., 2017, Thermal image acquisition and segmentation of human foot, *2017 4th International Conference on Signal Processing and Integrated Networks (SPIN)*, 80-85. <https://doi.org/10.1109/SPIN.2017.8049920>
- Szabo, T. L., 2013, *Diagnostic ultrasound imaging: inside out*, Academic press, p. <https://doi.org/10.1016/C2011-0-07261-7>
- Takayama, K. ve Nishina, H., 2007, Early detection of water stress in tomato plants based on projected plant area, *Environmental control in biology*, 45 (4), 241-249. <https://doi.org/10.2525/ecb.45.241>
- Tan, M. ve Le, Q., 2019, Efficientnet: Rethinking model scaling for convolutional neural networks, *International conference on machine learning*, 6105-6114. <https://doi.org/10.48550/arXiv.1905.11946>

- Trejo-Chavez, O., Amezquita-Sanchez, J. P., Huerta-Rosales, J. R., Morales-Hernandez, L. A., Cruz-Albarran, I. A. ve Valtierra-Rodriguez, M., 2022, Automatic Knee Injury Identification through Thermal Image Processing and Convolutional Neural Networks, *Electronics*, 11 (23), 3987. <https://doi.org/10.3390/electronics11233987>
- Triantafillou, E., Zhu, T., Dumoulin, V., Lamblin, P., Evci, U., Xu, K., Goroshin, R., Gelada, C., Swersky, K. ve Manzagol, P.-A., 2019, Meta-dataset: A dataset of datasets for learning to learn from few examples, *arXiv preprint arXiv:1903.03096*. <https://doi.org/10.48550/arXiv.1903.03096>
- Tucker, A. M., 1997, Common soccer injuries: diagnosis, treatment and rehabilitation, *Sports Medicine*, 23, 21-32. <https://doi.org/10.2165/00007256-199723010-00003>
- Verderber, L., Da Silva, W., Aparicio-Aparicio, I., Germano, A. M., Carpes, F. P. ve Priego-Quesada, J. I., 2024, Assessment of alternative metrics in the application of infrared thermography to detect muscle damage in sports, *Physiological Measurement*, 45 (9), 095014. <https://doi.org/10.1088/1361-6579/ad7ad3>
- Voinea, Ș.-V., Gheonea, I. A., Teică, R. V., Florescu, L. M., Roman, M. ve Selișteanu, D., 2024, Refined Detection and Classification of Knee Ligament Injury Based on ResNet Convolutional Neural Networks, *Life*, 14 (4), 478. <https://doi.org/10.3390/life14040478>
- Wang, L., Zhang, Y. ve Feng, J., 2005, On the Euclidean distance of images, *IEEE transactions on pattern analysis and machine intelligence*, 27 (8), 1334-1339. <https://doi.org/10.1109/TPAMI.2005.165>
- Wang, Y., Jiang, X., Yu, K., Shi, F., Qin, L., Zhou, H. ve Cai, F., 2021, Infrared thermal images classification for pressure injury prevention incorporating the convolutional neural networks, *IEEE Access*, 9, 15181-15190. <https://doi.org/10.1109/ACCESS.2021.3051095>
- Wolfe, W. L. ve Zissis, G. J., 1978, The infrared handbook, The Office, p.
- Xu, W., Fu, Y.-L. ve Zhu, D., 2023, ResNet and its application to medical image processing: Research progress and challenges, *Computer Methods and Programs in Biomedicine*, 240, 107660. <https://doi.org/10.1016/j.cmpb.2023.107660>
- Young, A., Hughes, I., Russell, P., Parker, M. ve Nichols, P., 1980, Measurement of quadriceps muscle wasting by ultrasonography, *Rheumatology*, 19 (3), 141-148. <https://doi.org/10.1093/rheumatology/19.3.141>
- Zakaria, N. ve Hassim, Y. M. M., 2024, A Review Study of the Visual Geometry Group Approaches for Image Classification, *Journal of Applied Science, Technology and Computing*, 1 (1), 14-28. <https://doi.org/10.30880/jastec.2024.01.01.003>
- Zhang, J., Lu, C., Li, X., Kim, H.-J. ve Wang, J., 2019, A full convolutional network based on DenseNet for remote sensing scene classification, *Mathematical Biosciences and Engineering*, 16 (5), 3345-3367. <https://doi.org/10.3934/mbe.2019167>
- Zhao, H., Shi, J., Qi, X., Wang, X. ve Jia, J., 2017, Pyramid scene parsing network, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2881-2890. <https://doi.org/10.48550/arXiv.1612.01105>
- Zhong, Z., Zheng, M., Mai, H., Zhao, J. ve Liu, X., 2020, Cancer image classification based on DenseNet model, *Journal of physics: conference series*, 012143. <https://doi.org/10.1088/1742-6596/1651/1/012143>

**EKLER****EK-1 Termal görüntülerin alınması ve araştırma yapılması için etik kurul kararı**

Evrak Tarih ve Sayısı: 26.02.2020-934

T.C.  
KTO KARATAY ÜNİVERSİTESİ TIP FAKÜLTESİ  
İLAÇ VE TIBBİ CİHAZ DIŞI ARAŞTIRMALAR ETİK KURUL KARARI

Toplantı Sayısı: 2

Toplantı Tarihi:24.02.2020

**Karar Sayısı: 2020/005:** Doç. Dr. Murat CEYLAN'ın "Profesyonel Futbolcularda Yararlanmanın Termografik Profile Etkisi" başlıklı araştırma projesi çalışması ile ilgili 17.02.2020 tarihli dilekçesi ve ekleri görüşüldü.

Görüşme sonucunda araştırma projesi çalışmasının Doç. Dr. Murat CEYLAN'ın sorumluluğunda yürütülmesinin uygun olduğuna oy birliği ile karar verildi.

**Not:** Çalışma ile ilgili gerekli izin ve yasal sorumluluk araştırmacılara aittir.

**Sorumlu Araştırmacı:** Doç. Dr. Murat CEYLAN

**Yardımcı Araştırmacı:** Ahmet BAYRAK, Mehmet Celalettin ERGENE

**ASLI GİBİDİR**  
24.02.2020

**Prof. Dr. Taner ZİYYAN**

**İlaç ve Tıbbi Cihaz Dışı Araştırmalar  
Etik Kurul Başkanı**